



**You have downloaded a document from
RE-BUS
repository of the University of Silesia in Katowice**

Title: Dwuetapowa metoda eksploracji danych pozyskiwanych z obrazów cyfrowych

Author: Anna Wójcicka

Citation style: Wójcicka Anna. (2016). Dwuetapowa metoda eksploracji danych pozyskiwanych z obrazów cyfrowych. Praca doktorska. Katowice: Uniwersytet Śląski

© Korzystanie z tego materiału jest możliwe zgodnie z właściwymi przepisami o dozwolonym użytku lub o innych wyjątkach przewidzianych w przepisach prawa, a korzystanie w szerszym zakresie wymaga uzyskania zgody uprawnionego.



UNIwersYTET ŚLĄSKI
W KATOWICACH



Biblioteka
Uniwersytetu Śląskiego



Ministerstwo Nauki
i Szkolnictwa Wyższego

UNIWERSYTET ŚLĄSKI W KATOWICACH



**Wydział Informatyki i Nauki o Materiałach
Instytut Informatyki**

mgr inż. Anna Wójcicka

**DWUETAPOWA METODA EKSPLORACJI DANYCH
POZYSKIWANYCH
Z OBRAZÓW CYFROWYCH**

ROZPRAWA DOKTORSKA

Promotor:

prof. dr hab. inż. Zygmunt Wróbel

Promotor pomocniczy:

dr inż. Roman Simiński

Sosnowiec 2016

Wyrazy podziękowania kieruje do **Prof. dr hab. inż. Zygmunta Wróbla** za podjęcie się roli opiekuna naukowego oraz do **dr. inż. Romana Simińskiego** za ukierunkowanie mojej pracy naukowej, zainspirowanie działań w zakresie tematyki stanowiącej podstawę badań, za poświęcony czas oraz cenne i trafne uwagi.

Składam serdeczne podziękowania **dr inż. Joannie Jaworek – Korjakowskiej,**
dr med. Monice Machoy oraz **dr inż. Adamowi Pietrasowi**
za udostępnienie danych do badań.

Moim najbliższym oraz **pracownikom Instytutu Techniki**
Uniwersytetu Pedagogicznego im. KEN w Krakowie
a w szczególności **prof. dr hab. inż. Krzysztofowi Mroczce**
za wiarę i udzielone wsparcie.

Spis treści

| | | |
|-------|--|----|
| 1 | Wprowadzenie | 5 |
| 1.1 | Teza i cel rozprawy | 7 |
| 1.2 | Struktura pracy | 9 |
| 2 | Motywacja i koncepcja proponowanego rozwiązania..... | 11 |
| 2.1 | Motywacja pracy..... | 11 |
| 2.2 | Koncepcja proponowanej metody..... | 13 |
| 3 | Ilościowe i jakościowe algorytmy analizy i przetwarzania obrazu | 16 |
| 3.1 | Ekstrakcja danych jakościowych | 18 |
| 3.1.1 | Przekształcenia geometryczne obrazu..... | 19 |
| 3.1.2 | Przekształcenia punktowe - bezkontekstowe | 20 |
| 3.1.3 | Przekształcenia lokalne - kontekstowe..... | 27 |
| 3.1.4 | Przekształcenia widmowe w dziedzinie częstotliwości..... | 35 |
| 3.1.5 | Przekształcenia morfologiczne..... | 36 |
| 3.2 | Ekstrakcja danych ilościowych..... | 40 |
| 3.2.1 | Etykietowanie – liczebność elementów..... | 40 |
| 3.2.2 | Pole powierzchni | 41 |
| 3.2.3 | Długość Krawędzi | 41 |
| 3.2.4 | Współczynniki kształtu | 42 |
| 3.3 | Ilościowe i jakościowe algorytmy do analizy obrazów medycznych | 43 |
| 3.4 | Zestaw algorytmów analizy i przetwarzania zastosowany w dalszej analizie | 45 |
| 4 | Analiza metod eksploracji danych | 48 |
| 4.1 | Eksploracyjna analiza danych — wprowadzenie..... | 49 |
| 4.2 | Metody eksploracji danych | 51 |
| 4.3 | Regułowa reprezentacja wiedzy, rodzaje reguł..... | 55 |
| 4.4 | Reguły a wydobywanie wiedzy z obrazów cyfrowych..... | 57 |
| 4.5 | Dobór metodyki generowania reguł..... | 59 |
| 5 | Podstawy teorii zbiorów przybliżonych..... | 61 |
| 5.1 | System informacyjny i relacja nierozróżnialności | 61 |
| 5.2 | Aproksymacja zbiorów | 63 |
| 5.3 | Istotność informacji, redukcja danych | 64 |
| 5.4 | Tablice decyzyjne | 66 |
| 5.5 | Spójność tablicy decyzyjnej..... | 68 |
| 5.6 | Reguły decyzyjne..... | 70 |
| 6 | Metody ekstrakcji reguł decyzyjnych | 71 |

| | | |
|-------|---|-----|
| 6.1 | Metody bazujące na teorii zbiorów przybliżonych | 71 |
| 6.1.1 | Podejście trywialne..... | 71 |
| 6.1.2 | Generowanie nietrywialnych zbiorów reguł | 73 |
| 6.2 | Inne metody generowania reguł decyzyjnych | 76 |
| 6.3 | Reguły asocjacyjne | 78 |
| 7 | System implementujący dwuetapową metodę eksploracji danych graficznych..... | 80 |
| 7.1 | Etap pierwszy — analiza obrazów | 80 |
| 7.1.1 | Ustalenie danych wejściowych | 81 |
| 7.1.2 | Wybrane elementy analizy obrazów | 83 |
| 7.1.3 | Prezentację wyników 1-go etapu..... | 86 |
| 7.1.4 | Prezentacja danych wejściowych dla etapu 2-go | 87 |
| 7.2 | Etap drugi — eksploracja danych | 87 |
| 7.2.1 | Kontrola spójności..... | 87 |
| 7.2.2 | Generowanie reguł | 89 |
| 7.2.3 | Wykorzystanie reguł..... | 89 |
| 7.3 | Zagadnienia implementacyjne | 91 |
| 8 | Badania i eksperymenty | 92 |
| 8.1 | Obrazy stomatologiczne..... | 92 |
| 8.1.1 | Etap pierwszy — analiza i przetwarzanie obrazów..... | 92 |
| 8.1.2 | Drugi etap metody – ekstrakcja wiedzy | 96 |
| 8.1.3 | Podsumowanie i ocena metody | 101 |
| 8.2 | Obrazy mikroskopowe złącz zgrzewanych wykonywanych metodą Friction Stir Welding..... | 101 |
| 8.2.1 | Etap pierwszy — analiza i przetwarzanie obrazów..... | 101 |
| 8.2.2 | Drugi etap metody – ekstrakcja wiedzy | 103 |
| 8.2.3 | Podsumowanie i ocena metody | 105 |
| 9 | Podsumowanie | 106 |
| 10 | Spis rysunków | 109 |
| 11 | Spis tabel..... | 111 |
| 12 | Literatura..... | 112 |

1 Wprowadzenie

Eksploracja danych jest aktualnie dziedziną badań naukowych dostarczającą znaczących rezultatów zarówno w ich aspekcie teoretycznym jak i praktycznym. Opracowane metody eksploracji danych pozwalają na analizę zbiorów danych, ukierunkowaną na wykrywanie istotnych prawidłowości, zależności, powiązań i relacji, zapisanych niejawnie w owych zbiorach. Metody eksploracji danych zakładają najczęściej, iż danymi wejściowymi są odpowiednio przetworzone dane jakościowe oraz ilościowe, reprezentowane zwykle w postaci tabelarycznej. Rezultatem badań eksploracyjnych zwykle jest wiedza kodyfikowana z wykorzystaniem reprezentacji regułowej. Reguły będące wynikiem eksploracji wykorzystywane są w różny sposób, np.: do budowy klasyfikatorów lub baz wiedzy systemów zaliczanych do klasy systemów ekspertowych. Zarówno klasyfikatory jak i systemy wykorzystujące bazy wiedzy oraz algorytmy wnioskowania są interesującym narzędziem badań w wielu dziedzinach, mają również znaczny potencjał wdrożeniowy, stanowiąc m.in. podstawę wielu użytecznych narzędzi wspomagania procesów diagnostycznych i decyzyjnych. Dla większości znaczących metod eksploracji zakłada się, że danymi wejściowymi będą wstępnie opracowane dane jakościowe i ilościowe, opisujące poddawane analizie informacje dziedzinowe. Taka forma danych wejściowych umożliwia stosunkowo łatwe pobranie danych z baz danych, arkuszy kalkulacyjnych jak i odpowiednio sformatowanych plików tekstowych.

Jednocześnie można zaobserwować ciągły rozwój popularności metod pozyskiwania danych reprezentowanych w postaci obrazów. Spowodowane jest to ciągłym rozwojem technologicznym urządzeń do rejestrowania obrazów, oraz wzrostem ich dostępności, do czego przyczyniają się m.in.: ich spadające ceny. Dotyczy to zarówno urządzeń popularnego zastosowania, jak i specjalizowanych urządzeń, stosowanych w wielu dziedzinach badawczych jak i zastosowaniach przemysłowych. Urządzenia te znajdują zastosowanie w wielu dziedzinach, stając się źródłem ogromnej ilości danych reprezentowanych w formie obrazów cyfrowych, niosących często wiele istotnych informacji. Jednak wydobywanie tych informacji bywa utrudnione ze względu na wysoką liczebność przetwarzanych zbiorów obrazów oraz konieczność poddawania ich nietrywialnym analizom. Wydobywaniem informacji z obrazów cyfrowych skutecznie zajmuje się analiza obrazów. Istnieje ogromna liczba uznanych publikacji wykazujących, że badania prowadzone w tej dziedzinie pozwalają na skuteczne

odkrywanie cech ilościowych oraz jakościowych charakteryzujących obiekty występujące na zarejestrowanych obrazach. Wiele badań z zakresu analizy obrazów w istocie ma charakter eksploracyjny — ukierunkowana jest właśnie na odkrywanie wyrażalnych jakościowo lub ilościowo informacji ukrytych w obrazach, a dotyczących zarejestrowanych na nich obiektów.

Wydaje się, że dane będące wynikiem badań wykorzystujących analizę obrazów, powinny być idealnym materiałem wejściowym dla eksploracji danych. Analiza spójnej serii obrazów pewnych obiektów pozwolić może na wydobywanie z nich serii interesujących cech owych obiektów, a poddanie ich dalszej analizie eksploracyjnej może pozwolić na odkrycie występujących regularności, uogólnień, powiązań i zależności. Te z kolei, zapisane w postaci np.: reguł, stanowią mogące być materiałem wejściowym, pozwalający na stworzenie systemu z regułową bazą wiedzy, który z wykorzystaniem metod automatycznego wnioskowania, pozwoli na prowadzenie badań o charakterze klasyfikacyjnym lub będzie mógł wspomagać podejmowanie decyzji w zakresie określonej dziedziny problemu.

Przykładem dziedziny, w której powiązanie pomiędzy wynikami analizy obrazów a eksploracją danych może być bardzo istotne, jest medycyna. W diagnostyce medycznej powszechnie wykorzystuje się obrazy rejestrowane w trakcie różnorodnych badań m.in.: rentgenowskich, ultrasonograficznych, tomograficznych czy rezonansowych. Obrazy te są zwykle wykorzystywane do diagnostyki konkretnych pacjentów, jednak ich odpowiednio przygotowane archiwum może stanowić podstawę do przeprowadzenia ogólniejszych badań, poświęconych przykładowo analizie pewnej jednostki chorobowej. Analiza obrazów dostarczyć może istotnych informacji wydobytych z obrazów. Eksploracja danych pozwolić może na wydobywanie wiedzy zapisanych w tych informacjach. Wiedza sformułowana w postaci reguł pozwolić może zarówno na ukierunkowanie dalszych badań w danej dziedzinie, jak i ostatecznie na realizację konkretnego systemu wspomagania diagnostyki w ramach rozważanej jednostki chorobowej.

Studia literaturowe przeprowadzone przez autorkę, wykazały jednak, że podejście spójnie łączące te dwie dziedziny są niezwykle rzadko stosowane. Oczywiście bardzo często konkluzje prac związanych z ekstrakcją danych z obrazów zawierają informacje o planach kontynuacji badań z wykorzystaniem metod odkrywania wiedzy, jednak trudno znaleźć prace, dokumentujące badania, które w sposób uporządkowany i metodyczny łączą oba podejścia.

Wskazać można wiele przyczyn takiego stanu rzeczy. Jedną z nich jest specjalizacja badań i zespołów badawczych, koncentrujących się albo na analizie obrazów, albo na eksploracji danych. Dotychczasowe badania pozwalają na stwierdzenie, że istnieje brak spójnego powiązania, łączącego eksplorację cech w obrębie analizy obrazów z analizą eksploracyjną w ramach odkrywania wiedzy w danych. Oba te podejścia działają w sposób niezależny, posługując się odmiennym podejściem do problemu i stosowanymi metodami badawczymi. Kluczowym problemem wydaje się skoordynowanie celów i wyników ekstrakcji cech z celami oraz specyfiką metod eksploracji danych w taki sposób, aby wyniki działania metod analizy obrazu dostarczały właściwie opracowanych danych dla metod ekstrakcji wiedzy, zachowując korelację pomiędzy celami zakładanymi na każdym z etapów badań. Osiągnięcie proponowanej korelacji pomiędzy obiema metodami może nie być możliwe bez udziału ekspertów dziedzinowych. Zakłada się, że wiedza dziedzinowa może mieć kluczowe znaczenie dla powiązania obu podejść badawczych oraz weryfikacji poprawności i skuteczności tego powiązania.

1.1 Teza i cel rozprawy

Głównym celem badawczym pracy jest opracowanie dwuetapowej metody wydobywania wiedzy z obrazów cyfrowych, integrującej analizę obrazów cyfrowych ukierunkowaną na ekstrakcję cech jakościowych i ilościowych z metodami ekstrakcji wiedzy, wykorzystującymi eksploracyjną analizę danych. Proponowana metoda ma zmaksymalizować możliwości automatyzacji pozyskiwania wiedzy z obrazów, umożliwiając jednocześnie na wykorzystanie wiedzy oraz kompetencji ekspertów dziedzinowych. Propozycja opracowania dwuetapowej metody eksploracji danych graficznych poprzedzona została badaniami wstępnymi, zrealizowanymi z wykorzystaniem obrazów z zakresu inżynierii materiałowej – złącza wytwarzane w technologii Friction Stir Welding oraz obrazów medycznych. Wyniki tych badań przedstawiono w publikacjach [1][2]. Badania wstępne wskazują na potrzebę opracowania spójnej metody eksploracji danych pozyskiwanych z obrazów cyfrowych. Literatura przedmiotu nie zawiera dobrze udokumentowanych badań w tym zakresie. Analiza wyników dotychczasowych badań potwierdza realizowalność badań oraz osiągalność proponowanych celów. Badania wstępne wskazują również na istotną wartość poznawczą proponowanych dalszych badań, przewidywany wkład w rozwój

dziedziny, jaką jest eksploracja danych oraz potencjał aplikacyjny w wielu dziedzinach naukowych oraz zastosowaniach praktycznych. Proponowane w ramach niniejszej pracy badania, w sensie praktycznym, osadzone będą w problematyce ekstrakcji wiedzy z obrazów medycznych jak i mikroskopowych złącz FSW. Powyższe spostrzeżenia pozwalają na sformułowanie następujących hipotez badawczych:

- Analiza obrazów dostarcza szerokiego spektrum metod pozwalających na ekstrakcję cech ilościowych i jakościowych z obrazów. Analiza tych metod, osadzona w kontekście późniejszej eksploracji wydobytych cech, pozwoli na wyodrębnienie zestawu skutecznych operacji z zakresu analizy obrazów, co umożliwi przygotowanie danych dla metod wydobywania wiedzy.
- Eksploracyjna analiza danych dostarcza szeregu metod odkrywania wiedzy z danych. Analiza tych metod dla danych będących wynikiem analizy obrazów pozwoli na zidentyfikowanie metod najlepiej dostosowanych do specyfiki tego typu danych.
- Połączenie metod ekstrakcji cech wywodzących się z analizy obrazów z metodami eksploracji danych pozwoli na stworzenie dwuetapowej metody odkrywania wiedzy w obrazach cyfrowych. Umożliwi to częściowo zautomatyzowane pozyskiwanie wiedzy z danych graficznych.
- Wykorzystanie wiedzy i kompetencji ekspertów dziedzinowych pozwoli na skorelowanie i właściwe z punktu widzenia specyfiki problemu przeprowadzenie obu etapów eksploracji. Jednocześnie będzie możliwa weryfikacja efektów działania metody.

Powyższe hipotezy pozwalają na sformułowanie następującej tezy:

Opracowanie dwuetapowej metody łączącej ekstrakcję cech ilościowych i jakościowych z obrazów cyfrowych oraz eksploracyjną analizę danych, pozwoli na prowadzenie nowego rodzaju badań eksploracyjnych, ukierunkowanych na wydobywanie wiedzy z obrazów cyfrowych, umożliwiających tworzenie regułowych baz wiedzy dla systemów wspomagania decyzji.

Głównym celem praktycznym jest opracowanie systemu informatycznego, wykorzystującego proponowaną dwuetapową metodę ekstrakcji reguł z danych graficznych. System umożliwiać będzie wydobywanie wskazanych cech obiektów zapisanych w serii obrazów cyfrowych, co będzie realizowane z wykorzystaniem

wyselekcjonowanych metod analizy obrazów. Jej wynikiem będzie system informacyjny, który po przekształceniu w tablicę decyzyjną pozwoli na automatyczne generowanie reguł. Wynikiem dwuetapowego procesu eksploracji będzie regułowa baza wiedzy. Na każdym z obu etapów oraz na etapie ich korelacji i weryfikacji wyników wykorzystana może być wiedza ekspertów dziedzinowych. Proponowany system będzie umożliwiał wykorzystanie uzyskanych reguł dla celów klasyfikacyjnych. Warto podkreślić, że danymi wejściowymi dla zadań klasyfikacyjnych jak i procesów wnioskowania mogą być dane w postaci obrazów. Szczegółowe cele badawcze, odpowiadające postawionym wcześniej hipotezom, są następujące:

- Badania metod ekstrakcji cech ilościowych i jakościowych z obrazów, ukierunkowane na wyodrębnienie zestawu operacji, użytecznych w kontekście późniejszej analizy eksploracyjnej wydobytych cech.
- Badania metod eksploracji danych, ukierunkowane na ocenę ich skuteczności dla danych będących wynikiem analizy obrazów.
- Opracowanie metody połączenia ekstrakcji cech wywodzących się z analizy obrazów z eksploracją danych, umożliwiającej generowanie reguł z danych graficznych, uwzględniającej wiedzę oraz kompetencje ekspertów dziedzinowych.
- Opracowanie systemu informatycznego o wskazanych wcześniej możliwościach oraz weryfikacja skuteczności metody na danych rzeczywistych.
- Próba wdrożenia metody i dedykowanego systemu wspomagania decyzji w wybranej placówce medycznej.

1.2 Struktura pracy

Pierwszy rozdział pracy wprowadza do zagadnień poruszanych w pracy. Przedstawia motywację oraz koncepcję proponowanej dwuetapowej metody eksploracji danych z obrazów cyfrowych.

Drugi rozdział pracy obejmuje przegląd ilościowych i jakościowych algorytmów analizy i przetwarzania obrazu, w którym to opisano najważniejsze i najczęściej wykorzystywane techniki ekstrakcji danych ze zdjęć. Na podstawie szerokich badań literaturowych wyodrębniono zestaw algorytmów zastosowany w systemie informatycznym.

Trzeci rozdział poświęcony został analizie metod eksploracji w tym przedstawiono różne metody eksploracji danych oraz regułową reprezentację wiedzy. Rozdział zakończono prezentacją metod generowania reguł.

Następnie w rozdziale czwartym skupiono się na prezentacji teorii zbiorów przybliżonych. W tym na aproksymacji zbiorów, istotności informacji i redukcji danych. Przedstawiono definicję tablicy decyzyjnej oraz metody usuwania niespójności, kończąc na regułach decyzyjnych.

W piątym rozdziale przedstawiono metody ekstrakcji reguł decyzyjnych od podejścia trywialnego do nietrywialnych zbiorów reguł.

Szósty rozdział poświęcono opisowi i prezentacji autorskiego systemu implementującego dwuetapową metodę eksploracji danych graficznych na danych medycznych. W rozdziale zaprezentowano sposób przeprowadzenia analizy za pomocą systemu. Natomiast w rozdziale siódmym przedstawiono eksperymenty wykonane na kolejnych rzeczywistych zestawach danych – obrazach stomatologicznych oraz mikroskopowych powierzchni poprzecznych złącz zgrzewanych metodą FSW. Kolejny raz pokazano krok po kroku sposób działania oprogramowania, przedstawiono wyniki oraz sformułowano wnioski.

Rozdział ósmy to podsumowanie, w którym odniesiono się do postawionych hipotez oraz celów. Dodatkowo zawiera informacje o możliwościach wdrożenia i dalszej pracy nad oprogramowaniem.

2 Motywacja i koncepcja proponowanego rozwiązania

Rozdział ten przedstawia motywację pracy oraz koncepcję proponowanej, dwuetapowej metody eksploracji danych reprezentowanych w postaci obrazów cyfrowych.

2.1 Motywacja pracy

Rozwój technologii rejestrowania obrazów cyfrowych zaowocował dużą łatwością pozyskiwania różnorodnych obrazów cyfrowych. Dotyczy to zarówno urządzeń popularnego zastosowania, jak i specjalizowanych urządzeń, stosowanych w wielu dziedzinach badawczych jak i zastosowaniach przemysłowych. Istotnym obszarem wykorzystania obrazów cyfrowych jest medycyna. Aktualnie niemal niemożliwe jest prowadzenie efektywnego i skutecznego leczenia bez wykorzystania nowoczesnych narzędzi diagnostycznych. Wiele z nich opiera się na informacjach zarejestrowanych w postaci zdjęć, projekcji czy przekrojów m.in.: RTG, USG, MRI, scyntygrafia czy CT.

Łatwość pozyskiwania dużej liczby powtarzalnych obrazów pozwala je traktować, jako interesujące serie danych dla dalszych analiz. Rzeczywiście, wskazać można wiele istotnych badań wykorzystujących dane wyodrębnione z obrazów. Rzadko jednak dane wydobyte z obrazów w bezpośredni sposób stają się materiałem dla metod wydobywania wiedzy z danych, ukierunkowanych na wydobywanie uogólnień, prawidłowości, zależności czy relacji pomiędzy elementami obrazu, rozważanymi dla pewnej spójnej serii obrazów [3][4][5]. Drastycznym przykładem niech będzie badanie wpływu terapii na rozrost nowotworu mózgu, tutaj zwykle jedynymi danymi diagnostycznymi są wyniki badań rezonansowych czy tomograficznych. Seria zdjęć pochodzących z badań uszeregowanych w czasie niesie zapewne szereg istotnych informacji dla terapii konkretnego pacjenta, informacje te mogą jednak stanowić podstawę do uogólnień, być może wnieść istotny wkład w rozwój wiedzy w zakresie onkologii mózgu.

Postęp technologiczny w dziedzinie obrazowania medycznego pociągnął za sobą odpowiednio: projektowanie nowych urządzeń i wyposażenia do pozyskiwania i gromadzenia danych np.: systemy informatyki medycznej [6][7] - Radiological Information System (RIS) oraz Picture Archiving and Communication System (PACS), opracowania skutecznych metod digitalizacji pozyskanych obrazów jak również

opracowaniem nowych metod obróbki obrazów pozyskanych przy użyciu tych urządzeń. Na całym świecie prowadzi się intensywne prace, w ramach których niejednokrotnie bardzo wyrafinowane metody analizy obrazów skutecznie wspomagają procesy diagnostyczne.

Niestety wykorzystywanie obrazów graficznych, jako źródła dla eksploracji danych nie jest praktyką częstą [8]. Badania literaturowe wskazują, że dane wydobywane z obrazów poddawane są zwykle różnorodnym analizom, przy czym dominująca jest analiza statystyczna oraz metody niesformalizowane, nawiązujące do specyfiki danej dziedziny zastosowań, ich zakres oraz metoda realizacji wynikają właśnie z owej dziedziny. Poddanie takich danych analizie eksploracyjnej, ukierunkowanej na wydobywanie wiedzy jest bardzo rzadkie.

Istnieje wyraźna luka pomiędzy badaniami z zakresu analizy obrazów a badaniami związanymi z odkrywaniem wiedzy z danych. Proponowana praca ma stanowić pomost pomiędzy tymi dwoma dziedzinami, pozwalając na odkrywanie wiedzy z danych zapisanych w postaci obrazów. Materiałem wejściowym dla metod odkrywania wiedzy są dane, reprezentowane zazwyczaj w postaci tabelarycznej, wykorzystującej deskryptory wyrażone w postaci atrybutów oraz ich wartości. Efektem procesu ekstrakcji wiedzy są najczęściej reguły, opisujące zależności pomiędzy atrybutami warunkowymi i atrybutem (atrybutami) decyzyjnym. Atrybuty te bardzo często bezpośrednio, albo pośrednio, odpowiadają cechom ilościowym lub jakościowym wydobytych z obrazów cyfrowych. W praktyce badań bardzo często mamy do czynienia z obrazami lub seriami obrazów, które nie opisują jednego konkretnego przypadku, lecz stanowią charakterystykę pewnej grupy, np.: opis badań dla pewnej grupy pacjentów. Takie badania robi się szczególnie wtedy, gdy wiedza na temat diagnozowanego problemu nie jest kompletna lub wręcz nie istnieją jeszcze ustalone prawidłowości.

Szczególne przypadki stanowią sytuacja, w ramach której posiadamy obrazy opisujące nowy problem, dla którego nie określono jeszcze odpowiedniej wiedzy dziedzinowej, a obrazy stanowią właśnie źródło pozwalające na uzyskanie i sformułowanie wiedzy w nowych obszarach. Przykładem mogą być zdjęcia przedstawiające nieznaną anomalię, np.: deformację kości zobrazowaną na zdjęciach RTG, lub śledzenie tendencji wzrostowych guza mózgu. Dla takiej, nieznanej lub nie do końca zbadanej anomalii może nie istnieć jasno sformułowana wiedza, pozwalająca na przeprowadzenia procesu diagnostycznego. Zebrane materiały stanowią dopiero podstawę próby sformułowania prawidłowości występujących w owej serii obrazów.

W przypadku takich problemów medycznych, praca lekarzy diagnostów ma charakter wybitnie badawczy, ukierunkowany na odkrywanie prawidłowości i regularności, pozwalających na sformułowanie wskazań diagnostycznych. W takim przypadku ekstrakcja wiedzy z obrazów może mieć istotne znaczenie, nie ograniczając się jedynie do wspomagania narzędziowego, stanowiąc ważne narzędzie pozwalające na prowadzenie prac badawczych. Automatyzacja prac badawczych oferowana przez metodę odkrywania wiedzy w obrazach może mieć kluczowe znaczenie zarówno dla tempa realizacji prac, jak i dla ich jakości.

W przypadku, gdy wiedza wydobyta z danych graficznych jest zweryfikowana, i zaaprobowana przez ekspertów dziedzinowych, stanowić może podstawę dla realizacji dziedzinowego systemu wspomagania decyzji, dedykowanego dla osób niebędących specjalistami w danej dziedzinie. System taki wspierać może przykładowo lekarzy pierwszego kontaktu we wstępnym diagnozowaniu przypadków chorobowych wymagających dalszego skierowania do specjalistów lub wymagających dalszych badań.

2.2 Koncepcja proponowanej metody

Proponowana metoda eksploracji danych z obrazów cyfrowych zakłada podział na dwa etapy. Etap pierwszy wykorzystuje wyselekcjonowane metody analizy obrazów, ukierunkowane na wydobywanie cech ilościowych i jakościowych obiektów przedstawionych na obrazach. Zakłada się, że danymi wejściowymi dla wybranych metod będą serie obrazów, przedstawiających analizowane obiekty. Na etapie ekstrakcji cech:

- Ustalana będzie ich liczba, rodzaj, nazwy poszczególnych cech oraz nazwy lub zakresy wartości cech,
- Ustalany będzie zestaw przekształceń graficznych, którym poddawane będą obrazy w celu ich standaryzacji oraz w celu uzyskania wymaganych cech.

Proces ten będzie realizowany z wykorzystaniem dedykowanego systemu informatycznego, który zostanie zrealizowany w ramach pracy.

Wynikiem tego etapu są tabele z danymi, przyjmującymi postać systemu informacyjnego [9]. Zakłada się, że dane te poddawane będą przetwarzaniu wstępnemu, obejmującemu przetwarzanie danych brakujących, odstających, dyskretyzację wartości

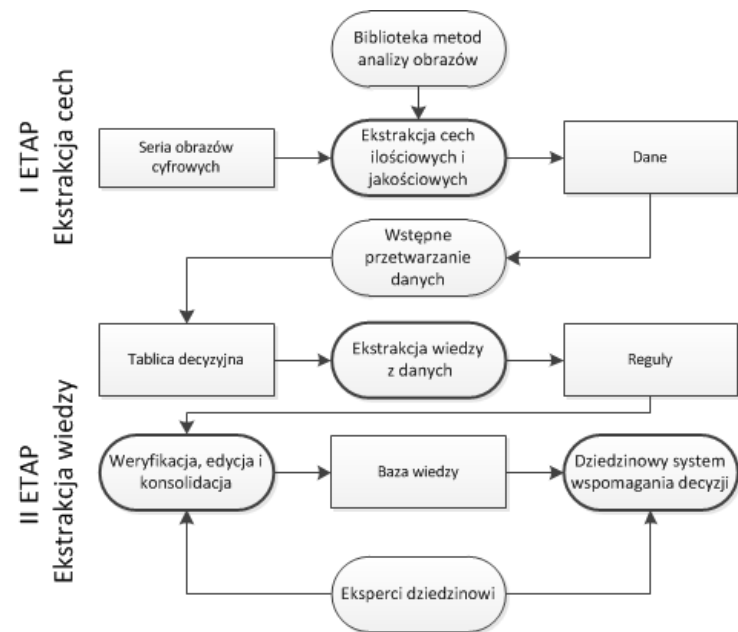
ciągłych. Wstępnie przetworzone dane utworzą tablicę decyzyjną [10], w której wskazany zostanie atrybut decyzyjny oraz atrybuty warunkowe.

Tablica decyzyjna stanowić będzie dane wejściowe dla drugiego etapu proponowanej metody. Etap ten obejmuje eksplorację danych, zakończoną wygenerowaniem reguł decyzyjnych. Proces ten poprzedzony będzie analizą spójności. Eksploracja danych opierać się będzie na podejściu bazującym na teorii zbiorów przybliżonych [9]. Wynikiem badań eksploracyjnych będą reguły decyzyjne. Zatem, na etapie ekstrakcji wiedzy:

- Przeprowadzana będzie analiza spójności tablicy wejściowej, zakłada się wykorzystanie różnych metod usuwania niespójności,
- Przeprowadzane będzie generowanie reguł decyzyjnych, zakłada się wykorzystanie różnych metod,
- Przeprowadzana będzie analiza, jakości uzyskanych reguł.

Drugi etap metody wykorzystywać będzie wsparcie ekspertów dziedzinowych, którzy z wykorzystaniem dedykowanego systemu będą mogli weryfikować uzyskane rezultaty z uwzględnieniem obrazów wejściowych. Szczególnym przypadkiem będzie analiza wyników ekstrakcji reguł dla różnych sekwencji obrazów, dotyczących tego samego problemu. Każda z sekwencji generować będzie bazę cząstkową. Proponowany system dostarczać będzie ekspertowi dziedzinowemu metod tworzenia wynikowej bazy wiedzy z wykorzystaniem baz cząstkowych. Schemat przedstawiony na Rys. 2.1 ilustruje koncepcję proponowanej metody.

Ostatnim elementem przewidywanej metody będzie możliwość wykorzystania utworzonej bazy wiedzy do realizacji dziedzinowego systemu wspomagania decyzji. Polegać to będzie na wykorzystaniu wbudowanego z system modułu wnioskowania w przód. Wnioskowanie to może być wykorzystane zarówno do badań eksperymentalnych i praktycznej weryfikacji otrzymanej bazy reguł, jak również do realizacji gotowego do wdrożenia systemu użytkowego.

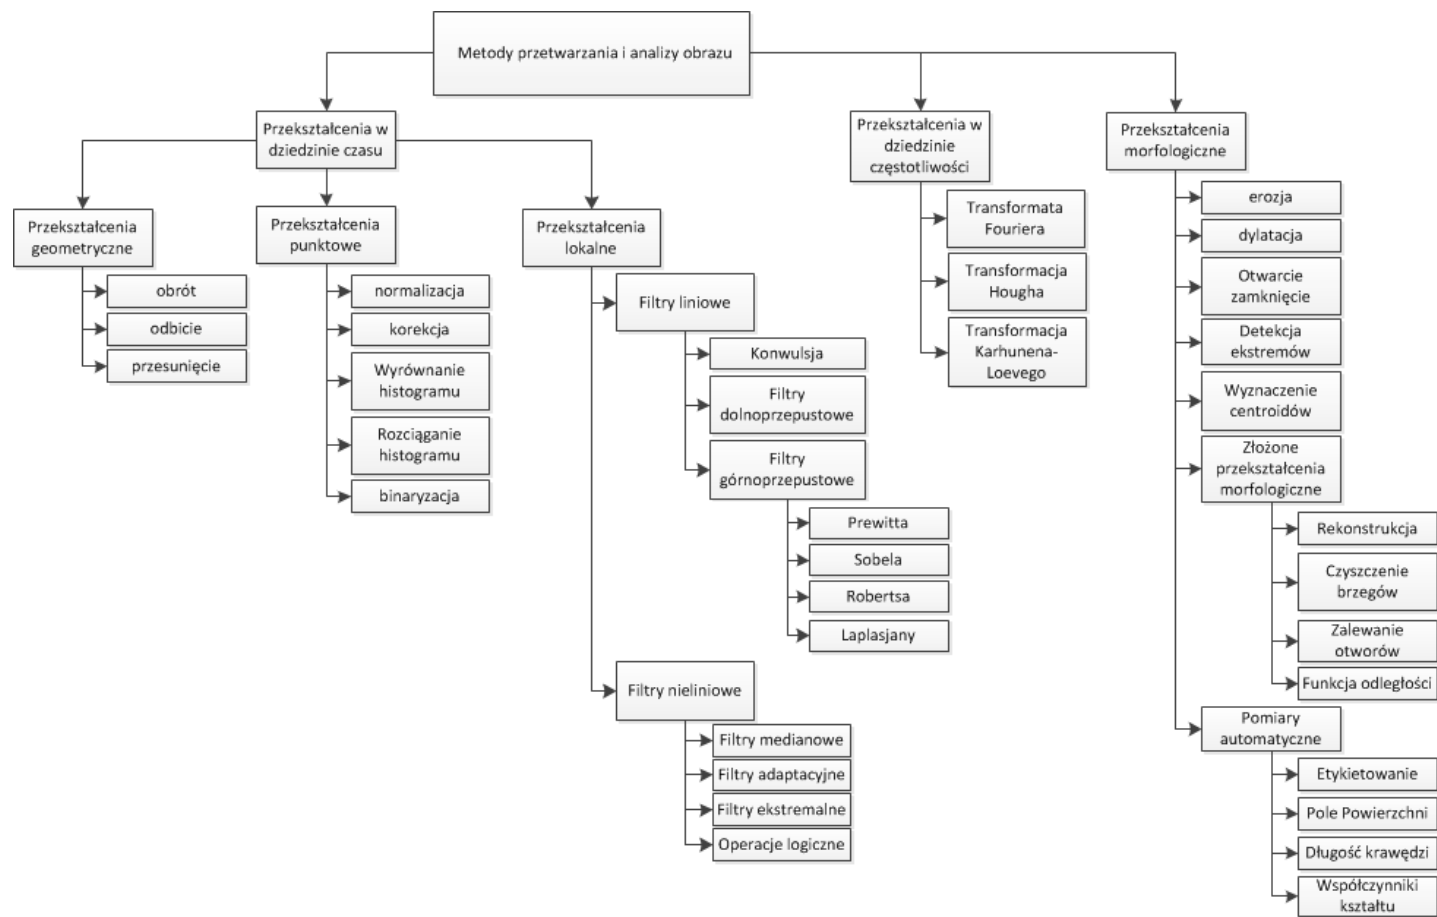


Rys. 2.1. Ilustracja koncepcji proponowanej metody ekstrakcji wiedzy z obrazów cyfrowych.

3 Ilościowe i jakościowe algorytmy analizy i przetwarzania obrazu

Rozdział ten poświęcony jest analizie metod przetwarzania i analizy obrazów pozwalających na określenie metod ekstrakcji cech ilościowych i jakościowych z obrazów. Jest on zgodny z pierwszym ze szczegółowych celów rozprawy, opisanych w podrozdziale 1.1. W rozdziale tym dyskutowane są metody i algorytmy z dziedziny analizy obrazów. Przedstawione rozważania ukierunkowane są na wyodrębnienie zestawu przekształceń graficznych, użytecznych w kontekście późniejszej analizy eksploracyjnej wydobytych cech.

Zwykle metody wydobywania informacji z obrazów ukierunkowane są na ekstrakcję parametrów ilościowych opisujących obrazy oraz ich cech jakościowych. Cechy jakościowe opisują zwykle ogólne charakterystyki obrazu – np. istnienie złamania kości, występowania guza, natomiast cechy ilościowe pozwalają na dokładne opisanie ich stopnia, rozmiaru, oraz np.: parametrów elementów otaczających. W literaturze dotyczącej metod przetwarzania obrazu zdefiniowana została duża liczba rozmaitych algorytmów przetwarzania obrazu stosowanych w praktyce [11][12][13][14][15][16][17][18][19][20][21]. Próbę sklasyfikowania powyższych metod przedstawiono na schemacie znajdującym się na Rys. 3.1.



Rys. 3.1. Podział metod analizy i przetwarzania obrazu.

3.1 Ekstrakcja danych jakościowych

W podrozdziale przedstawiono algorytmy analizy i przetwarzania obrazu, których zadaniem jest ekstrakcja cech. Cechy można definiować jako właściwości, które charakteryzują obiekty (jednostki statystyczne). Cechy możemy podzielić następująco:

- Cechy jakościowe (niemierzalne) - właściwości, których nie można scharakteryzować za pomocą liczb, można je opisać słowami np.: płeć: kobieta, mężczyzna.
- Cechy ilościowe (mieralne) – właściwości, które można wyrazić za pomocą jednostek miary w pewnej skali. Można je podzielić następująco:
 - Ciągłe – właściwości, które mogą przyjąć każdą wartość z określonego przedziału liczbowego, mierzone za pomocą jednostek fizycznych.
 - Porządkowe (quasi-ilościowe) – właściwości, które kwantyfikują natężenie badanej właściwości, wyrażonej w sposób opisowy, porządkując zbiorowość, np.: klasyfikacja wzrostu: niski, średni, wysoki.
 - Skokowe (dyskretne) – właściwości, które przyjmują skończony lub przeliczalny zbiór wartości na danej skali liczbowej np.: wiek (w rozumieniu liczba skończonych lat)

O ile wyodrębnienie algorytmów pozwalających na ekstrakcję cech ilościowych jest stosunkowo proste, tak określenie algorytmów odpowiedzialnych za jakościowy opis elementów przysparza już problemów, ponieważ łączy się on z problemem badawczym jaki został poddany analizie.

Zastosowanie kombinacji różnych przekształceń może w wielu wypadkach dać ten sam wynik końcowy. W innym wypadku z pozoru identyczna kombinacja przekształceń może doprowadzić do powstania kompletnie różniących się od siebie wyników końcowych. Świadczy to o dużej złożoności problemów przetwarzania obrazów jak i wielokrotnie od problemu jaki chcemy analizować na zarejestrowanych obrazach.

Niejednokrotnie ekstrakcja cech ilościowych obiektu może posłużyć do jej jakościowego opisu w późniejszej analizie. Przykładowo zastosowanie automatycznych pomiarów opisanych w podrozdziale 3.2 pozwala wydobyć dane numeryczne tj.: ilość

obiektów, pole powierzchni, udział procentowy itp. Liczby te mogą posłużyć do jakościowego opisu tych obiektów np.: małe, średnie, duże.

Opisane w podrozdziale algorytmy analizy i przetwarzania obrazu stanowią jedynie podstawowe informacje dotyczące najczęściej stosowanych operacji. Przedstawiono ich wpływ na obraz źródłowy powierzchni zęba. Spójna seria tych obrazów, oraz zestaw operacji analizy obrazu został następnie wykorzystany w eksperymentach realizowanych w systemie informatycznym (Rozdział 8.1). Przykład analizowanego obrazu źródłowego powierzchni zęba pokazano na Rys. 3.2. Obrazy zostały poddane przekształceniom w programie MatLab.



Rys. 3.2. Obraz powierzchni zęba zarejestrowany za pomocą tomografu optycznego.

3.1.1 Przekształcenia geometryczne obrazu

Przekształcenia geometryczne pozwalają na dopasowanie do siebie obrazów zarejestrowanych w różnym czasie lub za pomocą różnych źródeł. Do najczęściej wykorzystywanych operacji geometrycznych należy zaliczyć *obrót*, *odbicie* oraz *przesunięcie* obrazu.

Z przesunięcia obrazu, korzystamy w przypadku kiedy istnieje potrzeba przestrzennego dopasowania obrazów lub ich fragmentów. Obraz jest reprezentowany przez funkcję $L(m,n)$, gdzie argumenty dwuwymiarowej funkcji opisują powierzchniowe współrzędne piksela obrazu. Przesunięcie obrazu dane jest wzorem:

$$(m' = m_0 + m_i), \quad (3.1)$$

$$(n' = n_0 + n_i), \quad (3.2)$$

gdzie:

(m_0, n_0) – współrzędne początkowe pikseli

(m_i, n_i) – wartości przesunięcia współrzędnych pikseli

(m', n') – nowe wartości współrzędnych pikseli po przesunięciu

Obrót jest bardziej złożoną operacją, ponieważ wykorzystuje interpolację i korekcję współczynnika kształtu obrazu. Obrót obrazu $L(m, n)$ można wyrazić wzorem:

$$m' = m_0 \cos(\phi) - n_0 \sin(\phi), \quad (3.3)$$

$$n' = m_0 \sin(\phi) + n_0 \cos(\phi), \quad (3.4)$$

gdzie:

ϕ – kąt obrotu

Odbicie symetryczne polega na zmianie przyporządkowania pikseli. Odbicie symetryczne dane jest wzorem:

$$m' = (m_{max} - 1) - m, \quad (3.5)$$

$$n' = (n_{max} - 1) - n, \quad (3.6)$$

gdzie:

m_{max}, n_{max} – rozdzielczość obrazu wzdłuż osi m, n


Przekształcenia geometryczne sprawdzają się w przypadku obrazów zarejestrowanych za pomocą różnych urządzeń lub o zmiennych parametrach tj.: oświetlenie. W przypadku analizy spójnej serii obrazów przekształcenia geometryczne nie będą brane pod uwagę do implementacji w docelowym systemie informatycznym.

3.1.2 Przekształcenia punktowe - bezkontekstowe

Przekształcenia punktowe inaczej bezkontekstowe polegają na modyfikowaniu pojedynczych pikseli obrazu źródłowego w efekcie otrzymując przetworzony obraz wynikowy. W przypadku tego typu przekształceń zostaje zmieniona wartość (głównie

wartość jasności pikseli) poszczególnych pikseli, a jego parametry geometryczne pozostają bez zmian. Głównym celem zastosowania operacji punktowych jest poprawienie, uwypuklenie lub wykrycie cech zawartych na obrazie.


Normalizacja należy do przekształceń obrazu i pozwala na ogólne polepszenie jakości obrazu. Polega ona na zmianie wartości stopni szarości poszczególnych punktów obrazu źródłowego do ustalonego zakresu tych wartości na obrazie wynikowym [14][18]. Operację normalizacji stosuje się zazwyczaj kończąc lub poprzedzając inne przekształcenia obrazu. Na Rys. 3.3 przedstawiono wynik działania operacji normalizacji z użyciem następujących parametrów: $in\ low = 0,0$; $in\ high = 0,2$; $\gamma = 1$. Normalizacja pozwoliła usunąć niepotrzebne informacje – zakłócenia zarejestrowane na obrazie źródłowym. Jednocześnie w wyniku zastosowania tej operacji utracono informacje dotyczące wartości pikseli na powierzchni zęba.



Rys. 3.3. a) Obraz źródłowy zęba uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji normalizacji.


Wyrównanie (równoważenie) histogramu należy do jednopunktowych przekształceń stosunkowo często stosowanych w zastosowaniach praktycznych. Histogram definiujemy jako rozkład stopni szarości, przedstawiający częstość występowania poszczególnych pikseli na obrazie. W wyniku działania operacji wyrównania histogramu dochodzi do przekształcenia jasności poszczególnych pikseli obrazu tak, aby ilość pikseli o jasności leżącej w każdym z równych przedziałów histogramu była praktycznie taka sama. W wyniku działania tej operacji zostaje utracona część informacji na obrazie kosztem jego większej wyrazistości i czystości. Na Rys. 3.4 przedstawiono wynik działania operacji wyrównania histogramu. Jak można

zauważyć zastosowanie tego przekształcenia nie wpłynęło w sposób znaczący na obraz źródłowy.



Rys. 3.4. a) Obraz źródłowy zęba uzyskany za pomocą tomografu optycznego b) Obraz po operacji wyrównania histogramu.

Binaryzacja jest jednym z najważniejszych przekształceń obrazu, gdyż na obrazach binarnych wykonuje się większość pomiarów[17][18]. Binaryzacja ma na celu radykalne zmniejszenie informacji zawartych w obrazie, zwykle poprzedza analizę obrazu jak również jest często stosowana w procesie rozpoznawania. Binaryzacja polega na przekształceniu obrazu monochromatycznego posiadającego wiele poziomów szarości lub kolorowego na obraz, którego piksele przyjmują wartość 0 lub 1. Głównym problemem binaryzacji jest dobór odpowiedniej wartości progu binaryzacji. W celu wyznaczenia progu binaryzacji wykonuje się analizę histogramu. W najprostszym przypadku na histogramie możemy wyróżnić dwie krzywe – co oznacza, że na obrazie można wyróżnić dwa rodzaje często występujących wartości punktów – jasne oraz ciemne. Jedne stanowią analizowane obiekty, pozostałe stanowią tło. W takim przypadku można automatycznie wybrać próg binaryzacji, który będzie przyjmował minimalną wartość znajdującą się pomiędzy krzywymi. W przypadku analizowanych zdjęć dużo trudniej automatycznie określić próg binaryzacji, ponieważ na obrazie występuje więcej niż dwa odcienie szarości (0-255). Wybór progu binaryzacji będzie uzależniony od elementów jakie potrzeba uwidocznić na obrazie. Na Rys. 3.5 przedstawiono histogram dla obrazu źródłowego zęba.



Rys. 3.5. a) obraz źródłowy uzyskany za pomocą tomografu optycznego b) Histogram rozkładu stopni szarości.

- *Binaryzacja z dolnym progiem* – wszystkie piksele o wartości określonego progu binaryzacji przyjmują wartość 0 (stają się czarne), natomiast te które znajdują się powyżej wartości 1 (białe). Załóżmy, że obraz cyfrowy jest reprezentowany przez funkcję $L(m,n)$, a jej wartość określona jest poziomem jasności (szarości) obrazu, to binaryzację z dolnym progiem można określić za pomocą wzoru:

$$L'(m,n) = \begin{cases} 0; & L(m,n) \leq a \\ 1; & L(m,n) > a \end{cases}, \quad (3.7)$$

gdzie:

$L(m,n)$ – jasność punktu w obrazie źródłowym $L(m,n) \in [0, 2^B - 1]$


$L'(m,n)$ – wartość odpowiedniego punktu w obrazie wynikowym

$L'(m,n) \in \{0,1\}$

a – próg binaryzacji

B – liczba bitów dla reprezentacji jednego punktu obrazu (obraz monochromatyczny $B=8$)

Na Rys. 3.6 przedstawiono wynik działania binaryzacji z dolnym progiem, którego ustawiono na poziomie 40. W efekcie z obrazu źródłowego wyekstrahowano informacje dotyczące konturu zęba i podobnie jak w przypadku normalizacji utracono informacje dotyczące wartości pikseli na powierzchni zęba.




Rys. 3.6. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji binaryzacji z dolnym progiem.

- *Binaryzacja z górnym progiem* – polega na przyjęciu wartości 0 - koloru czarnego, przez wszystkie piksele znajdujące się powyżej ustalonego progu binaryzacji, natomiast poniżej tego progu wartości odpowiadające kolorowi białemu. Obraz po zastosowaniu binaryzacji z górnym progiem stanowi negatyw binaryzacji z dolnym progiem przy założeniu, że wartość progu zdefiniowana jest jednakowo. Binaryzację z górnym progiem można zapisać w postaci wzoru:

$$L'(m,n) = \begin{cases} 0; & L(m,n) \geq a \\ 1; & L(m,n) < a \end{cases} \quad (3.8)$$

Na rysunku Rys. 3.7 przedstawiono wynik zastosowania operacji z górnym progiem ustawionym na poziomie 180. Operacja ta nie przyczyni się do precyzyjnego wyznaczenia konturu zęba jak również informacji dotyczących wartości pikseli w centralnej części zęba.



Rys. 3.7. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji binaryzacji z górnym progiem.

- *Binaryzacja z podwójnym ograniczeniem (z dwoma progami)* dana jest wzorem (3.9). W wyniku tego przekształcenia wartości pikseli znajdujące się pomiędzy określonymi progami i przyjmują wartość 1 (są białe), natomiast punkty nieobjęte progiem pozostają czarne.


•

$$L'(m,n) = \begin{cases} 0; L(m,n) \leq a \\ 1; a_1 < L(m,n) \leq a_2, \\ 0; L(m,n) > a_2 \end{cases} \quad (3.9)$$

gdzie:

a_1, a_2 – progi binaryzacji, $a_1 < a_2$

Na Rys. 3.8. przedstawiono wynik działania binaryzacji z podwójnym progiem. Próg górny ustawiono na poziomie 40, natomiast próg dolny na poziomie 20. W efekcie można zaobserwować kontur zęba.



Rys. 3.8. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji binaryzacji z podwójnym ograniczeniem.


- *Binaryzacja warunkowa (z histerezą)* pozwala wyodrębnić z obrazu te elementy, które są jasne, przez co poprawiają selektywność procesu. Binaryzacja warunkowa dana jest wzorem (3.10), przy założeniu, że wartości progu binaryzacji spełniają warunek $a_1 < a_2$. Stopień szarości i intensywność $L(m, n)$ dla każdego punktu obrazu o współrzędnych (m, n) może zostać przekształcona następująco: Jeżeli $L(m, n) > a_1$ punkt przyjmuje kolor biały, $L(m, n) < a_2$ – kolor czarny, natomiast, jeżeli punkty obrazu spełniają warunek $a_1 < L(m, n) < a_2$ to zostają one przekształcone na punkty o kolorze białym, w przeciwnym wypadku punkty przyjmują wartość odpowiadającą kolorowi czarnemu.

$$L'(m, n) = \begin{cases} 0; & L(m, n) \leq a_1 \\ s; & a_1 < L(m, n) \leq a_2, \\ 1; & L(m, n) > a_2 \end{cases} \quad (3.10)$$

gdzie:

s – wartość sąsiadujących punktów, $s \in \{0,1\}$

Na Rys. 3.9 przedstawiono wynik zastosowania binaryzacji warunkowej z oknem o wymiarze 11 pikseli. Ta operacja w zdecydowanie najlepszy sposób pozwoli na ekstrakcję konturu. Linia konturu jest wyraźnie widoczna jak również nie są obserwowane znaczne ubytki i przerwania.



Rys. 3.9. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu binaryzacji warunkowej.

Analizując przekształcenia bezkontekstowe należy zwrócić uwagę jak ważne jest ich znaczenie zarówno w poprawie jakości obrazów jak również w wydobywaniu ukrytych elementów.

3.1.3 Przekształcenia lokalne - kontekstowe

Przekształcenia kontekstowe ingerują w zawartość obrazu jak również w geometrię zarejestrowanych na nim obiektów – oznacza to, że dla wyznaczenia wartości jednego piksela wynikowego należy wykonać serię określonych obliczeń na wielu pikselach obrazu źródłowego. Dzięki tym operacjom można usunąć elementy niepotrzebne tj.: szумы, zakłócenia, wydobyć pewne informacje niedostrzegalne dla ludzkiego oka jak również usunięcie wady obrazu np.: zarysowania obiektywu, poprawić obraz o złej jakości oraz dokonać rekonstrukcji obrazu. Operacje kontekstowe – filtry są pewnymi wieloargumentowymi funkcjami przekształcającymi piksel po pikselu. Wyróżniamy dwa rodzaje filtrów:

- Liniowe – obraz wejściowy zostaje poddany filtracji w oparciu o pewną liniową kombinację jego pikseli,
- Nieliniowe – Obraz wejściowy zostaje poddany filtracji w oparciu o nieliniową kombinację jego pikseli.

Przekształcenia liniowe

Konwulsja inaczej nazywana splotem funkcji jest dana wzorem:

$$g(x) = (f \times h)(x) = \int_{-\infty}^{+\infty} f(x-t)h(t)dt, \quad (3.11)$$


gdzie:

f, h – splatane funkcje

W powyższym wzorze funkcja h staje się filtrem ponieważ, splot (g) zdefiniowany jest na całym R , a iloczyn $f(x-t)h(t)$ jest całkowity na całym R . Funkcja h może posiadać skończoną dziedzinę. Dla obrazów $L(m, n)$ dziedzina funkcji jest dwuwymiarowa i dyskretna. Konwulsja dla obrazu dyskretnego przyjmuje postać:

$$L' = (m, n) = (w \times L)(m, n) = \sum_{i,j \in K} L(m-i, n-j)w(i, j), \quad (3.12)$$

Na Rys. 3.10. przedstawiono wynik zastosowania konwulsji z zastosowaniem parametrów $conv = [-1 \ -1 \ -1 \ -1 \ 12 \ -1 \ -1 \ -1 \ -1]$. Ta operacja podobnie jak binaryzacja warunkowa pozwala zaobserwować kontur zęba bez znacznych ubytków.



Rys. 3.10. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu konwulsji.

Filtry reprezentowane są przez tablicę współczynników $w(i, j)$. Współczynniki te wybiera się w taki sposób, aby przyjmowały wartości całkowite (normalizacja).


Współczynniki $w(i, j)$ oraz punkty obrazu $L(m - i, n - j)$ znajdujące się w obszarze K wokół punktu (m, n) służą łącznie do wyliczenia funkcji $L'(m, n)$ dla tego punktu w obrazie wynikowym.

Filtr dolnoprzepustowy to filtr uśredniający, którego macierz (o pewnych rozmiarach nazywanych maską) konwulsji przedstawiana jest następująco:


$$\begin{bmatrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{bmatrix} \quad \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix},$$

Po zastosowaniu filtru w obrazie likwidowane są niewielkie zakłócenia. Pojedyncze ciemne piksele zostają rozmazone podobnie jak jasne piksele na ciemnym tle. Zasadniczą wadą filtru dolnoprzepustowego jest rozmycie konturów obiektów, co powoduje problem z rozpoznaniem ich kształtu.

Na Rys. 3.11 przedstawiono wynik działania filtru dolnoprzepustowego – średnia. Natomiast Rys. 3.12 jest wynikiem działania filtru dolnoprzepustowego Gaussa, o rozmiarze 5×5 i parametrze $\sigma = 2$. Operacje te nie przyczyniły się do poprawy jakości zdjęcia, korekcji wad obrazu, jak również nie wzmocniły w obrazie żadnych elementów. Na obrazach można zauważyć lokalnie rozmycie.




Rys. 3.11. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru dolnoprzepustowego – średnia.




Rys. 3.12. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru dolnoprzepustowego Gamma.

Filtry górnoprzepustowe to typ filtrów służący głównie do uwypuklenia pewnych elementów obrazu np.: konturów, krawędzi, narożników oraz drobnych elementów faktury. Filtry górnoprzepustowe oprócz wzmacniania krawędzi powodują wydobywanie niepotrzebnych szczegółów w jednolitych obrazach.

Na Rys. 3.13 przedstawiono wynik działania filtru górnoprzepustowego Robertsa. Natomiast na kolejnym rysunku wynik działania filtru górnoprzepustowego mean removal. Filtr Robertsa nie pozwala na zidentyfikowanie konturu zęba jak również nie przyczynia się w żadnym stopniu do wydobywania interesujących informacji ze zdjęcia. Natomiast w przypadku filtru mean removal, można dostrzec poprawienie kontrastu zdjęcia.



Rys. 3.13. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru górnoprzepustowego Robertsa.



Rys. 3.14. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtra górnoprzepustowego – mean removal.


Szczególnym przypadkiem filtrów górnoprzepustowych są *Laplasjany*, które w przeciwieństwie do innych filtrów górnoprzepustowych wykrywających krawędzie i narożniki nie wykorzystując kierunkowego działania maski. Umożliwiają one wykrywanie i podkreślenie na obszarze wszystkich krawędzi i konturów obiektów niezależnie od tego, pod jakim kontem są ułożone. Matematycznie Laplasjan to kombinacja drugich pochodnych cząstkowych funkcji wejściowej $L(m,n)$ i dany jest wzorem:

$$L'(m,n) = \frac{\partial^2 L(m,n)}{\partial m^2} + \frac{\partial^2 L(m,n)}{\partial n^2} \quad (3.13)$$

W praktyce Laplasjan to wynik konwulsji obrazu z maską np.:

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad \begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad \begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

Na Rys. 3.15 przedstawiono wynik działania Laplasjanu o współczynniku = 0,1. W przypadku zęba zarejestrowanego na obrazie operacja Laplasjanu, która jest najkorzystniejsza do wykrywania wszelkich krawędzi i konturów obiektów, niezależnie pod jakim kątem one przebiegają nie daje zadowalających wyników. Maski Roberta Prewitta, Sobela wyznaczają krawędzie tylko w ośmiu kierunkach [18]. Filtry liniowe usuwając zakłócenia niszczą drobne szczegóły jak i krawędzie przetwarzanych obrazów.



Rys. 3.15. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu Laplasjanu.

Przekształcenia nieliniowe

Wśród filtrów nieliniowych wyróżniamy wiele funkcji różniących się właściwościami. Jednak ich wspólną cechą jest przetwarzanie obrazu w oparciu o nieliniową kombinację pikseli obrazu wejściowego.

Większość filtrów nieliniowych usuwających zakłócenia usuwa również drobne elementy i krawędzie obiektów. *Filtry medianowe* to szczególny przypadek filtrów nieliniowych, ponieważ nie posiadają wyżej opisanej wady. Działanie filtru można opisać w następujący sposób: dla pojedynczego przetwarzanego punktu wybiera się jedną z wartości punktu znajdującego się w otoczeniu przetwarzanego punktu na obrazie źródłowym.


Mediana rozumiana jest jako środkowa wartość piksela w uporządkowanym rosnąco ciągu wartości jasności pikseli w otoczeniu przetwarzanego punktu. Dla przykładu:

$$\begin{bmatrix} 12 & 45 & 3 \\ 1 & 197 & 10 \\ 8 & 13 & 15 \end{bmatrix}$$

Mediana dla podanych powyżej wartości {1,3,8,10,12,13,15,196} wynosi 12. W wyniku zastosowanego filtru medianowego wartość przetworzonego piksela będzie przyjmowała wartość 12 na obrazie wynikowym. Filtry medianowe skutecznie radzą sobie z lokalnymi szumami przy braku (na ogół) pogorszenia ostrości krawędzi

obiektów na obrazie wynikowym. Filtry medianowe mają również wady. Jedną z nich jest erozja obrazu, drugą natomiast długi czas obliczeń.

Na Rys. 3.16 przedstawiono wynik działania filtru medianowego o rozmiarze 3x3. W wyniku zastosowania tej operacji zostały usunięte drobne szумы, a ostrość krawędzi zęba nie uległa pogorszeniu.




Rys. 3.16. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru medianowego.

Filtry adaptacyjne zmieniają charakterystykę działania w zależności od cech obrazu. Działanie filtru adaptacyjnego uśredniającego można podzielić na dwa etapy:

- W pierwszej kolejności zostaje wyznaczony parametr klasyfikujący określający punkt na krawędzi. Takim kryterium może być np.: wariancja stopni szarości w otoczeniu punktu [14],
- Następnie przeprowadza się proces filtracji uśredniającej. Filtracji zostają poddane punkty niezakwalifikowane do krawędzi. Punkty należące do krawędzi nie zostają poddane działaniu filtru, przez co unika się ich rozmycia.

Na Rys. 3.17 przedstawiono wynik działania filtru adaptacyjnego o rozmiarze 3x3. Podobnie jak w przypadku filtru medianowego, na obrazie zostały zlikwidowane drobne szумы, a krawędzie zęba nie uległy pogorszeniu.




Rys. 3.17. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru adaptacyjnego.

Operacjom logicznym opartym na logice Boole'a poddaje się obrazy binarne przyjmujące wartości prawdy (1) lub fałszu (0). Charakterystyczną cechą operacji logicznych jest ich sposób działania – z dwóch obrazów źródłowych powstaje pojedynczy obraz wynikowy. Wśród operacji logicznych można wyróżnić:

- Negatyw obrazu.
- Iloczyn logiczny - Wycinanie obrazu za pomocą maski.
- Suma logiczna „fotomontaż”.
- Różnica logiczna.
- Suma rozłączna.
- Równoważność logiczna.

Dla obrazów zawierających więcej niż dwie wartości pikseli należy stosować logikę wielowartościową lub rozmytą.

Na Rys. 3.18 przedstawiono wynik działania operacji logicznych: sumy obrazu i filtru medianowego. Operacje logiczne wykonywane są najczęściej na obrazach binarnych, natomiast dla obrazów monochromatycznych, tradycyjna logika Bool'a jest niewystarczająca i należy zastosować logikę wielowartościową. Efekt operacji logicznych obrazów monochromatycznych nie jest tak spektakularny jak w przypadku obrazów binarnych.



Rys. 3.18. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji logicznych – suma obrazów oraz suma obrazu z filtrem medianowym.

3.1.4 Przekształcenia widmowe w dziedzinie częstotliwości

Transformata Fouriera jest przekształceniem w dziedzinie częstości przestrzennych obrazu. Rozkłada ona jasność obrazu na bazowe funkcje (części sinusowe i cosinusowe) o różnych częstościach. Dla obrazu cyfrowego o wymiarach $M \times N$ pikseli transformatę Fouriera przeprowadza się wg. wzoru:


$$F(i, k) = \beta_L \cdot \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} L(m, n) \exp\left(\frac{-2j\pi mi}{M}\right) \cdot \exp\left(\frac{-2j\pi nk}{N}\right), \quad (3.14)$$

dla: $i = 0, 1, \dots, M - 1$; $k = 0, 1, \dots, N - 1$


Rezultatem działania transformaty Fouriera jest funkcja w dziedzinie częstości reprezentująca widmo częstotliwościowe funkcji pierwotnej (obrazu). Operacje realizowane z wykorzystaniem transformaty Fouriera działają w obszarze globalnym. Punkt w płaszczyźnie częstości przestrzennych jest odzwierciedleniem wielu punktów w płaszczyźnie obrazu.

Obliczenia transformaty Fouriera wykonywane są dla każdego wiersza i każdej kolumny osobno, przez co czas obliczeń jest nieefektywny jednak zdecydowanie najprostszy. Nieco szybsze podejście zaproponowali autorzy, gdzie wykorzystali zestawy par wartości pikseli w całym dwuwymiarowym obrazie, prowadzi do powstania identycznych wyników [22][23]. Wiele bibliotek zawierających funkcje matematyczne posiada już zoptymalizowane operacje Szybkiej Transformaty Fouriera (FFT).

Na Rys. 3.19. oraz na Rys. 3.20. przedstawiono wynik zastosowania transformaty Fouriera.



Rys. 3.19. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) F-obraz fazy po wykonaniu transformaty Fouriera.



Rys. 3.20. F-obraz amplitudy po zastosowaniu transformaty Fouriera.

Przekształcenia widmowe a w szczególności najpopularniejsza transformata Fouriera, to operacje stosowane w szczególnych przypadkach. Na wstępnym etapie w systemie informatycznym nie zostaną zaimplementowane te przekształcenia.

3.1.5 Przekształcenia morfologiczne

Operacje morfologiczne służą do analizy kształtu jak również położenia elementów na obrazie i stanowią najważniejszy element komputerowej analizy obrazu. Podstawowym elementem w przeprowadzeniu operacji morfologicznych jest element

strukturalny stanowiący szablon lub wzorec. Jest to pewien wycinek obrazu lub podzbiór elementów obrazu. W przypadku dyskretnej reprezentacji obrazu, z wyróżnionym jednym punktem (tzw. punktem centralnym). Ze względu na ograniczenia związane z dyskretną strukturą obrazu podstawowym elementem strukturalnym jest prostokąt a nie koło o promieniu jednostkowym. Dzięki wyznaczeniu elementu strukturalnego operacje morfologiczne pozwalają na przekształcenie jedynie tej części punktów obrazu, którego otoczenie jest zgodne z elementem strukturalnym. Ta cecha operacji morfologicznych odróżnia je od innych typów przekształceń jak również pozwala na ich precyzyjne planowanie.

Ogólny algorytm operacji morfologicznych można przedstawić następująco:

- Umieszczenie centralnego punktu wzorca w każdym punkcie obrazu.
- Sprawdzenie czy lokalna konfiguracja punktów obrazu jest tożsama ze wzorcem.
- W przypadku wykrycia tożsamej struktury analizowanego obszaru obrazu. Wykonywane są ustalone operacje na badanym punkcie obrazu.

Erozja i dylatacja należą do podstawowych przekształceń morfologicznych. Działanie tych operacji polega na odcinaniu lub dodawaniu pikseli zgodnie z elementem strukturalnym. Operacje te zostały opracowane przez Hermanna Minkowskiego.

Erozja – odejmowanie Minkowskiego, wykonuje się według wzoru (3.15). Funkcję $L(m, n)$ poddaje się erozji elementem strukturalnym B z punktem centralnym Z [24].

$$\varepsilon_B(L(m, n)) = \min_{X_i, Y_i \in B(m, n)} L(m_i, n_i), \quad (3.15)$$


gdzie:

$L(m, n)$ – wartość funkcji dla współrzędnych (m, n)

$B(m, n)$ – element strukturalny z punktem centralnych

Erozja cechuje się niezmienniczością, monotonicznością oraz antyekstensywnością (gdy początek układu współrzędnych należy do zbioru B) [25].

Na Rys. 3.21 przedstawiono wynik działania operacji erozji z elementem strukturalnym „disc” o rozmiarze 3. W efekcie utracono znaczną ilość informacji dotyczącej konturu zęba.




Rys. 3.21. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji erozji.

Dylatacja funkcji $L(m, n)$ elementem strukturalnym B opisuje wzór [24]:

$$\delta_B(L(m, n)) = \max_{X_i, Y_i \in B(m, n)} L(m_i, n_i). \quad (3.16)$$

Dylatacja jest również fundamentalnym przekształceniem morfologicznym i ma wiele różnych właściwości m.in.: ekstensywność, monotoniczność oraz niezmienniczość względem przesunięcia[25].

Na Rys. 3.22. przedstawiono wynik działania operacji dylatacji z elementem strukturalnym „disk” o rozmiarze 3. Dylatacja pozwoliła na uwidocznienie konturu zęba.




Rys. 3.22. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji dylatacji.

Operację otwarcia i zamknięcia polegają na złożeniu operacji erozji i dylatacji i dane są wzorem[24]. *Otwarcie*:

$$\gamma_B(L(m,n)) = \delta_B(L(m,n)\varepsilon_{B^{\vee}}(L(m,n))). \quad (3.17)$$

Na Rys. 3.23 przedstawiono wynik działania operacji otwarcia z elementem strukturalnym „disc” o rozmiarze 3x3. Podobnie jak w przypadku erozji i dylatacji operacje otwarcia i zamknięcia powodują podobne efekty – w wyniku otwarcia zostaną utracone informacje natomiast operacja zamknięcia uwidoczniła kontur obiektu zarejestrowanego na obrazie.




Rys. 3.23. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji otwarcia.

Zamknięcie:

$$\varphi_B(L(m,n)) = \varepsilon_B(L(m,n)\delta_{B^{\vee}}(L(m,n))). \quad (3.18)$$

Na Rys. 3.24 przedstawiono wynik działania operacji otwarcia z elementem strukturalnym „disc” o rozmiarze 3x3.



Rys. 3.24. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji otwarcia.

Przekształcenia morfologiczne w docelowym programie są bardzo ważne ze względu na ich wykorzystanie w praktycznie każdej analizie. Operacje te mogą być łączone w zestawy, co pozwala wykonać bardziej złożone operacje pozwalające na analizę kształtu elementów jak również zależności pomiędzy obiektami.

3.2 Ekstrakcja danych ilościowych

Kończącym elementem analizy obrazu są pomiary, które pozwalają wyznaczyć cechy ilościowe określonego obrazu. Do pomiarów ilościowych możemy zaliczyć te o charakterze lokalnym: średnica obiektów/elementów lub ich średnia powierzchnia, natomiast do parametrów globalnych np.: ilość obiektów na jednostkę powierzchni czy udział procentowy wybranych elementów na obrazie.


3.2.1 Etykietowanie – liczebność elementów

Proces *etykietowania* polega na przypisaniu do wszystkich zidentyfikowanych pikseli danego obiektu tzw. etykiet – tych samych wartości pikseli. Pikselom należącym do jednego obiektu nadaje się tą samą wartość, czyli indeks. Ta sama etykieta – indeks nadawana jest każdemu punktowi, który jest w jego najbliższym otoczeniu. Każdy napotkany punkt nieposiadający jeszcze etykiety otrzymuje ją o numer większą i tak aż do przeanalizowania całego obrazu. Punkty, którym nadano już indeks są pomijane. Po zakończeniu procesu etykietowania, nie ma potrzeby zliczania punktów, ponieważ największy numer indeksu jest równoważny z liczbą występujących obiektów.

Etykietowanie jest wstępną operacją pozwalającą wykryć granicę obiektów i poddać je dalszym analizom.

3.2.2 Pole powierzchni

Pomiar pola powierzchni polega na sumowaniu/zliczaniu punktów należących do tego samego obszaru. Wycechowanie obrazu – pozwala odnieść zaznaczoną na obrazie wielkość do rzeczywistej odległości. Pole powierzchni jest parametrem, który łatwo wyznaczyć, jednak na jego dokładność duży wpływ ma próg określony podczas operacji binaryzacji. Na Rys. 3.25 przedstawiono pomiar pola powierzchni zajmowanej przez komórki nowotworowe [26], który sprowadza się do zliczenia pikseli należących do interesującego obrazu, czyli komórek nowotworowych. Po wycechowaniu obrazu, czyli podaniu rzeczywistej odległości jakie odpowiada odległość wyrażona w pikselach, można otrzymać wynik pomiaru w takich jednostkach jakie są wymagane.



Rys. 3.25. Pomiar pola powierzchni zajmowanego przez komórki nowotworowe jelita grubego.[26]

3.2.3 Długość Krawędzi

Pomiar długości krawędzi przysparza wielu problemów ze względu na przeprowadzenie linii ciągłej poprzez dyskretne punkty obrazu. Wyróżniamy kilka sposobów na pomiar długości:

- Zliczanie punktów brzegowych.
- Zliczanie punktów brzegowych figury z uwzględnieniem ich położenia.
- Wyliczenie średniej z długości zliczonych po zewnętrznej i wewnętrznej stronie brzegu figury.
- Przybliżenie figury odpowiednim wielokątem.
- Przybliżenie długości brzegu liniami krzywymi.
- Wykorzystanie formuły Croftona.

3.2.4 Współczynniki kształtu

Zasadniczą cechą współczynników kształtu jest dokładność z jaką odróżniamy od siebie elementy o różnych kształtach. Autorzy [14] wymieniają dwie zasadnicze grupy współczynników kształtu:

Pierwsza grupa współczynników charakteryzuje się dużą szybkością obliczeń w czasie rzeczywistym:

- Bezwymiarowy współczynnik kształtu do ilościowego charakteryzowania kształtu cząstek:

$$R_s = \frac{L^2}{4\pi S}, \quad (3.19)$$

gdzie:

L- obwód obiektu.

S- pole powierzchni obiektu.

- Współczynnik Fereta (charakteryzuje wydłużenie cząstki)

$$R_F = \frac{L_h}{L_v}, \quad (3.20)$$

gdzie:

L_h - maksymalna średnica obiektu w poziomie

L_v – maksymalna średnica obiektu w pionie

- Współczynnik cyrkularności:

$$R_{C1} = 2\sqrt{\frac{S}{\pi}}, \quad (3.21)$$

$$R_{C2} = \frac{L}{\pi}. \quad (3.22)$$

- Współczynnik Malinowskiej

$$R_M = \frac{L}{2\sqrt{\pi S}} - 1. \quad (3.23)$$

Druga grupa to współczynniki, w których szybkość obliczeń nie jest aż tak istotna jak dokładność pomiaru. Do tej grupy zaliczamy:

- Współczynnik Blaira-Blissa

$$R_B = \frac{s}{\sqrt{2\pi \sum_i r_i^2}}, \quad (3.24)$$

gdzie:

r_i – odległość piksela obiektu od środka ciężkości obiektu

i – numer piksela obiektu

- Współczynnik Danielssona

$$R_D = \frac{s^3}{(\sum_i l_i)^2}, \quad (3.25)$$

gdzie:

l_i – minimalna odległość piksela obiektu od konturu obiektu

- Współczynnik Haralicka

$$R_H = \sqrt{\frac{(\sum_i d_i)^2}{n \sum_i d_i^2 - 1}}, \quad (3.26)$$

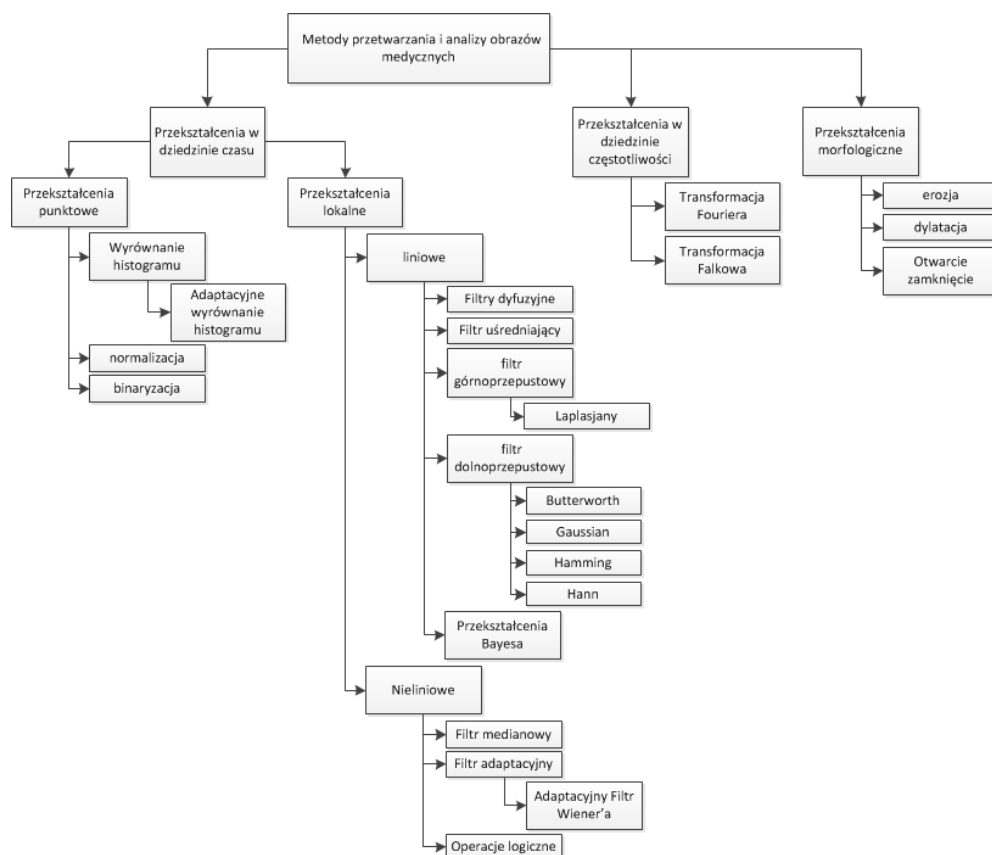
gdzie:

d_i – odległość pikseli konturu obiektu od jego środka ciężkości

n – liczba pikseli konturu

3.3 Ilościowe i jakościowe algorytmy do analizy obrazów medycznych

Jak sugeruje literatura rodzaj zastosowanej metody przetwarzania obrazu jest zależny od typu obrazu i od końcowego celu jego analizy, np. oceny diagnostycznej. Dlatego też możliwych sposobów przetworzenia jednego obrazu w inny jest nieskończenie wiele. Autorzy prac [3][27][28][29] z ogromu dostępnych metod i algorytmów przetwarzania obrazu wykazują, te najistotniejsze z punktu przydatności w procesie diagnozy medycznej i stomatologicznej. Na podstawie czego można było stworzyć schemat najczęściej stosowanych metod analizy obrazów medycznych stosowanych w praktyce, przedstawionych na Rys. 3.26.



Rys. 3.26. Najczęściej stosowane metody przetwarzania obrazów medycznych i stomatologicznych.

W obrazowaniu medycznym, w celu poprawy jakości zdjęć bardzo istotną rolę spełnia przetwarzanie wstępne obrazów, które polega głównie na poprawie kontrastu, redukcji szumów czy podkreślaniu różnic między obiektami, poprzez zastosowanie przekształceń geometrycznych i punktowych. Przekształcenia geometryczne stosowane są w praktycznie wszystkich przypadkach, gdzie jest mowa o wstępnym przetwarzaniu obrazu, a ich głównym celem jest przygotowanie obrazu do dalszej obróbki poprzez takie operacje jak skalowanie, obrót, przesunięcie itp. Operacje punktowe takie jak np.: wyrównanie histogramu umożliwiają również poprawę jakości obrazu uwidaczniając elementy wstępnie niedostrzegalne. Swoje zastosowanie znajdują czasem w procesie wykrywania krawędzi.

Do metod umożliwiających wyróżnienie obiektów na obrazach możemy zaliczyć również różnego rodzaju filtry. Przykładem zastosowania mogą być filtry dolnoprzepustowe i górnoprzepustowe [30]. Innym zastosowaniem przekształceń lokalnych, takich jak filtry liniowe i nieliniowe, jest usuwanie szumów, których rodzaj rozproszenia wpływa na wybór konkretnego filtru. W artykule [31] autor posłużył się filtracją medianową jako jedną z operacji umożliwiających wstępną obróbkę zdjęć

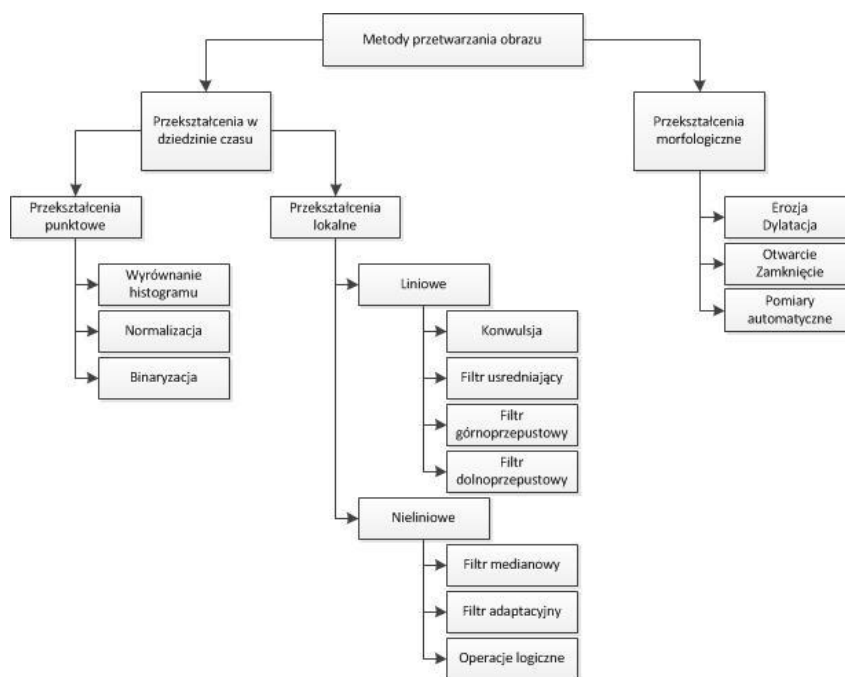
pochodzących z tomografu optycznego oraz do określenia grubości szkliwa jak również określenia zarysu zęba. Filtracja medianowa ma dwie wady, nie usuwa szumów na krawędziach oraz może zmieniać przebieg krawędzi w sposób przypadkowy. Alternatywą jest zastosowanie filtrów dyfuzyjnych [32], które umożliwiają wygładzenie krawędzi, a ze względu na intuicyjne zachowanie procesu dyfuzji oraz swoją prostotę zyskały dużą popularność.

Usuwanie szumów z wykorzystaniem przekształceń Bayesa jest sporadycznie stosowane [33], natomiast dużą rolę odgrywa w procesie segmentacji obrazu, w celu wykrywania granic obiektów w tym przypadku narządów np.: wykrywanie guza w mammografii i radiologii [34][35][36] w MRI [37][38] oraz tomografii komputerowej. Transformacja Falkowa wykorzystana jest np.: do przetwarzania sygnału EKG [39]. Kombinacja transformacji Falkowej, filtracji medianowej oraz filtracji krawędziowej została zaproponowana w pracy [40]. Natomiast autor [41] również wykorzystał kombinację transformacji Falkowej, ale z algorytmami segmentacji do ilościowej oceny naczyń wieńcowych, usprawniając proces diagnozy chorób serca takich jak zwężenie tętnic sercowych. Oprócz przedstawionych powyżej praktycznych zastosowań algorytmów służących do wstępnej analizy wyróżnić można jeszcze znacznie więcej przykładów. Niemniej istotny jest fakt, że już na tym etapie możliwa jest ekstrakcja pewnych cech jakościowych i ilościowych obiektów na badanych obrazach. Autorzy książek [27][28][29] wskazują, że ekstrakcję cech można przeprowadzić również poprzez proces segmentacji. Pozycje [3][42][43] stanowią obszerne i wyczerpujące studium nad metodami segmentacji obrazów medycznych.

3.4 Zestaw algorytmów analizy i przetwarzania zastosowany w dalszej analizie

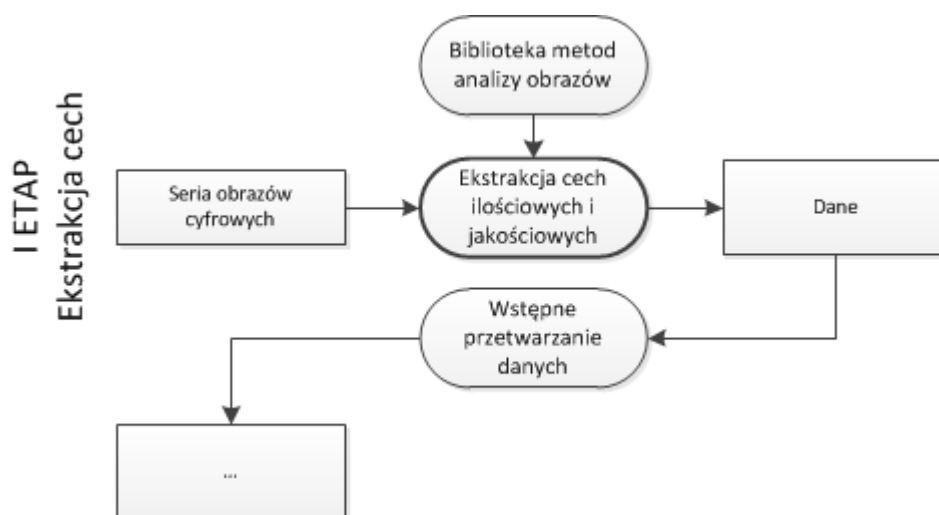
Na podstawie powyższej analizy literatury, doświadczeń własnych oraz subiektywnej oceny dostępnego oprogramowania wyodrębniono bibliotekę najczęściej wykorzystywanych metod analizy obrazów do zaimplementowania w docelowym systemie informatycznym. Analiza pozwoliła na wyselekcjonowanie metod ukierunkowanych na wydobywanie cech ilościowych i jakościowych obiektów przedstawionych na obrazach, które będą najistotniejsze w początkowej wersji programu (Rys. 3.27).

Wśród przekształceń punktowych wyodrębniono operację wyrównania histogramu, normalizacji i przede wszystkim binaryzację. Głównie ze względu na szerokie zastosowanie w poprawie, uwypukleniu lub wykrywaniu cech zawartych na obrazie. Przekształcenia lokalne ograniczono do zaimplementowania podstawowych filtrów tj.: górno i dolnoprzepustowego, filtru uśredniającego, medianowego oraz adaptacyjnego, głównie ze względu na to, że pozwalają wydobyć informacje ukryte w obrazach skutecznie usuwając szумы i obrazując elementy nie widoczne dla ludzkiego oka. Największy nacisk położono na operacjach pozwalających na ekstrakcję cech ilościowych obiektów zarejestrowanych na obrazach. Dlatego też przekształcenia morfologiczne a w szczególności pomiary automatyczne mają istotne znaczenie w docelowym programie informatycznym.



Rys. 3.27. Wyselekcjonowane metody analizy i przetwarzania obrazu.

Rozdział ten stanowi realizację celów badawczych związanych z wytypowaniem algorytmów analizy i przetwarzania obrazu pozwalających na ekstrakcję danych jakościowych i ilościowych oraz przygotowanie ich do kolejnego etapu metody ukierunkowanego na ekstrakcję wiedzy. Schemat pierwszego etapu analizy przedstawiono na Rys. 3.28.



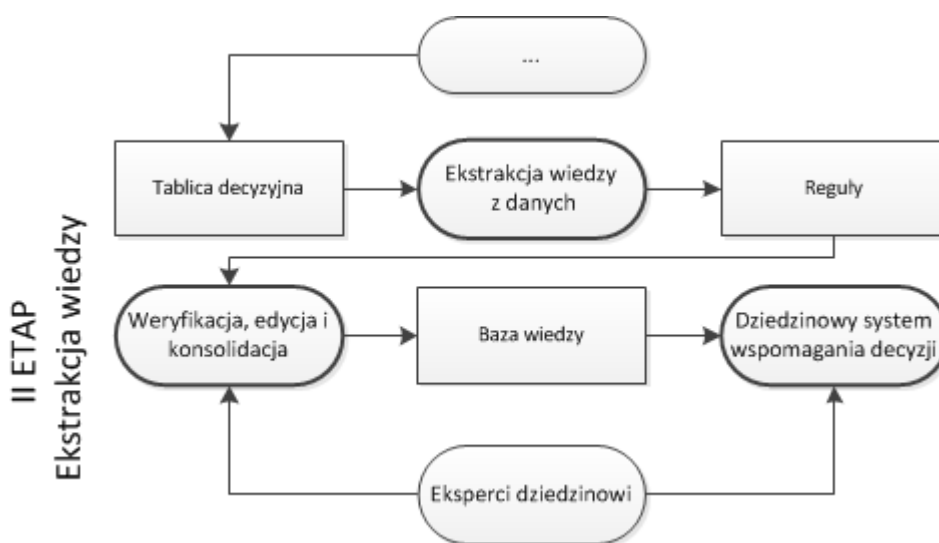
Rys. 3.28. Schemat pierwszego etapu metody ukierunkowanej na ekstrakcję cech.

Etap pierwszy wykorzystuje wyselekcjonowane metody analizy obrazów ukierunkowanych na wydobywanie cech ilościowych i jakościowych z danych wejściowych, jakimi jest spójna seria obrazów cyfrowych przedstawiających analizowane obiekty. Na tym etapie ustalana jest liczba, rodzaj oraz nazwy poszczególnych cech jak również wartości tych cech. Następnie obrazy zostaną poddane zestawowi przekształceń graficznych w celu standaryzacji a następnie w celu uzyskania wymaganych cech. Wynikiem tego etapu będą tabele z danymi, które podlegają wstępnemu przetworzeniu obejmującemu przetwarzanie danych brakujących, odstających oraz dyskretyzację wartości ciągłych. Tak przygotowane dane stanowią dane wejściowe do drugiego etapu metody – ekstrakcji wiedzy.

4 Analiza metod eksploracji danych

Proponowana w niniejszej pracy metoda zakłada, iż wyniki ekstrakcji cech bazującej na algorytmach analizy obrazu zostaną wykorzystane jako dane wejściowe dla etapu ekstrakcji wiedzy, wykorzystującej eksploracyjną analizę danych. Rozdział ten obejmuje krótką charakterystykę istoty eksploracji danych, przegląd stosowanych metod oraz analizę ukierunkowaną na ocenę skuteczności ich działania dla danych będących wynikiem analizy obrazów. Rezultatem przeprowadzonej analizy będzie wskazanie kategorii metod eksploracyjnych najlepiej odpowiadających założeniom proponowanej, dwuetapowej metody analizy danych pozyskiwanych z obrazów cyfrowych.

Zakłada się, że dane wejściowe dla etapu eksploracji będą miały postać systemu informacyjnego [9], którego reprezentacją jest tabela. Wiersze tabeli reprezentują obiekty opisywane przez analizowane obrazy, a kolumny reprezentują atrybuty, opisujące wyodrębnione cechy ilościowe i jakościowe. Celem etapu eksploracyjnego jest wydobywanie wiedzy opisującej ukryte w danych zależności, opisujące związki pomiędzy cechami oznaczonymi jako warunkowe a cechami wskazanymi jako decyzyjne. W takim ujęciu spodziewanym wynikiem etapu eksploracyjnego są reguły, na zbudowanie docelowego systemu wspomagania decyzji (zgodnie ze schematem przedstawiającym II etap metody zawartym na Rys. 4.1.).



Rys. 4.1. Schemat drugiego etapu metody.

4.1 Eksploracyjna analiza danych — wprowadzenie

Rozwój technologii informatycznych doprowadził do dużej łatwości pozyskiwania, gromadzenia i magazynowania różnorodnych informacji w obrębie praktycznie dowolnej dziedziny. Intensywny rozwój systemów zarządzania bazami danych oraz ich dostępność, pozwalają na uporządkowane i magazynowanie dużych zbiorów danych [44]. Systemy informatyczne gromadzące dane stały się powszechnie dostępne, a gromadzone dane bardzo zróżnicowane. To już nie tylko klasyczne dane w postaci liczb, napisów i tekstów, to również dane multimedialne, w tym, istotne z punktu widzenia niniejszej pracy, dane w postaci obrazów cyfrowych. Niezależnie od charakteru zgromadzonych zbiorów danych, mogą one stanowić cenne źródło interesujących, ważnych, użytecznych oraz nietrywialnych informacji. Wydobywanie takich informacji jest jednym z wiodących kierunków badawczych zarówno w obrębie badań z zakresu samej informatyki jak i dziedzin powiązanych poprzez specyfikę owych danych, np. badań z zakresu szeroko rozumianego biznesu czy medycyny.

Wydobywanie owych użytecznych a nietrywialnych zależności występujących w sposób niejawny w zbiorach danych bywa bardzo różnie definiowane, a istniejące metody bywają bardzo różnie klasyfikowane. W ujęciu bliskim technologii baz danych oraz zastosowaniom ekonomicznym wydobywanie za agregowanych informacji z dużych zbiorów danych było domeną hurtowni danych oraz systemów OLAP (ang. *On-line Analytical Processing*) [45]. Jednak zbiory danych mogą być nie tylko źródłem zależności mających charakter zagregowanej informacji. Zbiory danych mogą być źródłem wiedzy, opisującej w uogólniony sposób prawidłowości, trendy, podobieństwa, zależności występujące w analizowanych zbiorach danych. Wydobywanie tak rozumianej wiedzy jest podstawowym celem dziedziny badań określanej mianem odkrywania wiedzy w danych (ang. *Knowledge discovery in data*) [46].

Odkrywanie wiedzy jest pojęciem o charakterze ogólnym [47][46] i obejmuje cały proces odkrywania wiedzy, składający się z szeregu kroków prowadzących od surowych danych, do odkrytych w nich wzorców. Kroki te obejmują m.in. czyszczenie, selekcję, integrację, transformację danych [47][46]. Jednym z etapów odkrywania wiedzy jest eksploracja danych (ang. *Data mining*). Stanowi ona kluczowy element odkrywania wiedzy, pozostałe elementy tego procesu mają dane właściwie przygotować oraz umożliwić właściwą reprezentację, interpretację oraz wizualizację odkrytej wiedzy [45]. W procesie odkrywania wskazuje [46][48][49] się następujące etapy:

1. Czyszczenie zbioru danych, polegające zwykle na usunięciu danych niepełnych, niepoprawnych lub zbędnych.
2. Integrację danych w jeden spójny zbiór.
3. Selekcję danych, polegającą na wyznaczeniu danych istotnych z punktu widzenia procesu odkrywania wiedzy.
4. Konsolidacja i transformacja wyselekcjonowanych danych do postaci wymaganej przez metody eksploracji danych.
5. Wybór metody eksploracji danych i jej realizacja.
6. Interpretacja i analiza otrzymanych wyników, ocena i identyfikacja interesujących wzorców.
7. Wizualizacja wyników w przystępnej formie umożliwiającej interpretację i zrozumienie przez użytkownika.

W tym kontekście opisane wcześniej rozważania dotyczące ekstrakcji cech z obrazów cyfrowych wpisują się w koncepcję przygotowania danych dla procesu eksploracji danych, stanowiąc specyficzną realizację postulatów wstępnego etapu odkrywania wiedzy w danych — wyżej opisanych punktów 1-4.

Eksploracja danych bywa definiowana w materiałach źródłowych bardzo różnie [47][46][48][50][49][51]. Wspólnym mianownikiem owych definicji jest stwierdzenie, że jest to proces automatycznego odkrywania nietrywialnych, dotychczas nieznanых, interesujących wzorców w dużych zbiorach danych. Odkrywane wzorce nazywane bywają również modelami. Przez wzorec (ang. *pattern*) rozumie się pewną regularność pomiędzy danymi, przy czym zwykle te wykryte regularności odnoszą się nie do pojedynczych danych a raczej do ich agregacji. W kontekście procesu odkrywania wiedzy, wzorec jest pewną formą reprezentacji wiedzy, większość metod zakłada więc, iż wzorec przyjmuje postać jednej z ogólnie przyjętych reprezentacji wiedzy w dziedzinie sztucznej inteligencji. Najczęściej stosowane formy reprezentacji wzorców to reguły asocjacyjne, drzewa i reguły decyzyjne, formuły logiczne, modele regresji wielowymiarowej, zależności ilościowe wyrażone w postaci równań, skupienia obiektów czy Bayesowskie sieci przekonań [52].

Warto zwrócić uwagę, na rolę człowieka w procesie odkrywania wiedzy i eksploracji danych. O ile w zagadnieniu eksploracji zakładamy automatyczne działanie pewnej metody, o tyle — w rozumianym szerzej — odkrywaniu wiedzy człowiek powinien uczestniczyć w kolejnych etapach procesu odkrywania wiedzy. To właśnie znajomość dziedziny pozwolić właściwie sterować procesem odkrywania

wiedzy [46]. Proponowana w niniejszej pracy metoda odkrywania wiedzy zakłada również intensywny udział człowieka, szczególnie na etapie przygotowania danych graficznych, co zostało przedstawione we wcześniejszym rozdziale, poświęconym analizie obrazów.

4.2 Metody eksploracji danych

Można wskazać wiele metod oraz technik realizacji postulatów eksploracji danych, wywodzących się z różnych dyscyplin badawczych. Eksploracja ma charakter interdyscyplinarny i w różnym stopniu wykorzystuje dokonania statystyki, uczenia maszynowego, przetwarzania danych niepewnych (np.: teorii zbiorów rozmytych czy teorii zbiorów przybliżonych). To właśnie uczenie maszynowe i statystyka mają obecnie największe znaczenie z uwagi na dostarczanie algorytmów dla odkrywania wiedzy [52].

Metody eksploracji można różnie klasyfikować ze względu na cel eksploracji, typy eksplorowanych danych oraz typy odkrywanych wzorców. Zdecydowanie częściej w literaturze [50][53][49] spotyka się podział ze względu na cel eksploracji:

- Klasyfikacja i predykcja.
- Odkrywanie asocjacji.
- Grupowanie.
- Odkrywanie charakterystyk.
- Odkrywanie wzorców sekwencji i podobieństw w przebiegach czasowych.
- Wykrywanie zmian i odchyleń.

Klasyfikacja i predykcja jest jednym istotniejszych trendów w eksploracji danych. Jej celem jest przewidywanie przyszłych lub nieznanych wartości pewnych atrybutów na podstawie wykrytych wzorców. Zadaniem predykcji jest przewidywanie nieznanego wartości pewnego atrybutu charakteryzującego obiekt, opierając się o zbiór znanych wartości atrybutów opisujących obiekty. Atrybut charakteryzujący obiekt zwany jest zwykle atrybutem decyzyjnym, wartość tego atrybutu dzieli zbiór obiektów na pewne klasy. Najpopularniejszym wykorzystaniem tej metody jest odkrywanie modeli – klasyfikatorów, które można wykorzystać do klasyfikacji nowych obiektów.

Początkowym krokiem budowy klasyfikatora jest zbiór obiektów historycznych, stanowiący listę wartości deskryptorów wybranego atrybutu decyzyjnego, nazywany

zbiorem przypadków, obserwacji i próbek, który dzielimy na zbiór treningowy i testowy [45]. W oparciu o zbiór treningowy danych budowany jest klasyfikator (faza treningu lub uczenia). W fazie testowania, w oparciu o zbiór testowych danych szacowana jest jakość klasyfikatora, na podstawie współczynnika dokładności. Współczynnik ten określa procent przykładów testowych poprawnie zaklasyfikowanych przez klasyfikator. W zależności od współczynnika dokładności, odporności na szum, błędów w danych treningowych, skalowalność oraz interpretowalność można wyróżnić wiele metod klasyfikacji [50][54][55][49]. Te najpopularniejsze wykorzystują reguły decyzyjne, drzewa decyzyjne, klasyfikatory bayesowskie, sieci neuronowe, SVM, kNN. Metody bazujące na regułach decyzyjnych są szczególnie istotne dla metody proponowanej w niniejszej pracy.

Kolejnym ważnym podejściem do eksploracji danych jest *odkrywanie asocjacji*. Ta popularna oraz bardzo użyteczna metoda pozwala na odkrycie interesujących zależności lub korelacji, nazywanymi asocjacjami, między danymi w dużych zbiorach [56][50][57][58][53][59][55][60][61]. W wyniku zastosowania metody odkrywania asocjacji otrzymujemy zbiory reguł asocjacyjnych, opisujących wykryte zależności i korelacje. Reguły asocjacyjne przypominają w pewnym stopniu reguły decyzyjne (opisywane wcześniej w kontekście klasyfikacji i predykcji), jednak w przypadku reguł asocjacyjnych część decyzyjna reguły zawierać może dowolny atrybut nierozważany w części warunkowej.

Istnieje wiele rodzajów reguł asocjacyjnych [50][53][60][61][49] i można je klasyfikować według takich kryteriów jak: typ przetwarzanych danych, wymiarowość i stopień abstrakcji przetwarzanych danych. Najpopularniejszy przykład zastosowania reguł asocjacyjnych to analiza koszyka zakupów, ukierunkowana na odkrywaniu wzorców zachowań klientów. Polega ona na znalezieniu grup wspólnie kupowanych produktów. Formalny opis reguł asocjacyjnych oraz metod ich odkrywania wywodzi się właśnie z analizy koszykowej, choć poszukiwanie asocjacji znalazło wiele innych zastosowań [53].

Grupowanie jest procesem polegający na łączeniu obiektów o podobnych cechach w grupy zwane klastrami lub skupieniami [46][48][50][62][63][64]. W sensie ogólnym grupowanie polega na znajdowaniu skończonego zbioru kategorii opisujących dane. Kategorie te mogą być rozłączne, zupełne, mogą też tworzyć struktury hierarchiczne i nakładać się na siebie. Proces grupowania można podzielić na kilka etapów:

- Przygotowanie danych – ekstrakcja/selekcja najbardziej istotnych cech i przygotowanie bazy danych dla stosowanych narzędzi.
- Szacowanie - Wybór miary podobieństwa pomiędzy obiektami oraz tworzenie klastrów.
- Właściwe grupowanie - znalezienie czytelnego opisu klastrów.
- Walidacja – sprawdzenie czy otrzymany opis klastrów odzwierciedla wejściowy zbiór danych.

Metody i algorytmy grupowania możemy podzielić na [65][45]:

- Metody hierarchiczne – w których skupienia tworzą drzewa. W takiej reprezentacji liście stanowią poszczególne obiekty, a węzły grupy tych obiektów. Wśród metod hierarchicznych wyróżniamy: metody aglomeracyjne i podziałowe:
 - Metody oparte o teorię grafów.
 - Metody analizy skupień.
 - Metody partycyjne i algorytmy genetyczne.
 - Metody oparte o sieci neuronowe.
- Metody optymalizacyjne – iteracyjne (np.: k-means, k-medoids)
- Metody deterministyczne i probabilistyczne - metoda przeszukiwania przestrzeni stanów wszystkich możliwych partycji zbioru grupowanych obiektów –
- Metody generujące klastry rozłączne i przecinające się, ze względu na charakter znajdowanych klastrów
- Metody wykorzystywania cech obiektów w procesie grupowania – metody monoatrybutowe i poliatrybutowe,
- Metody odświeżania klastrów – metody przyrostowe lub takie gdzie proces grupowania jest realizowany od początku

Odkrywanie charakterystyk polega na odnajdywaniu zwięzłych opisów podanego zbioru danych. Taki opis zbioru danych można uzyskać w różny sposób:

1. Odkrywanie charakterystyki zbioru danych (zbioru celowego). Zbiór celowy utworzony jest poprzez zapytania do bazy danych. Następnie zbiór zostaje poddany analizie w celu znalezienia charakterystyki. Wynik odkrywania

zbiorów danych ma najczęściej postać wykresów graficznych lub reguł charakterystycznych. [46][50]

2. Analizę dyskryminacyjną zbioru danych dotyczących porównania podstawowych cech zbioru celowego z cechami zbioru kontrastującego – porównawczego. Zbiór kontrastujący jest tworzony tak jak zbiór celowy poprzez zapytania do bazy. Następnie dane zbiory poddane są analizie z zastosowaniem metod takich jak w przypadku odkrywania charakterystyk. W tym wypadku wynik można przedstawić w postaci wykresów i reguł dyskryminacyjnych.[46][50]
3. Połączenie obu technik

Odkrywanie charakterystyk ma zastosowanie jako niezależna metoda eksploracji danych, jak również może być elementem innej metody np.: grupowania. W pracy [50] podane jest wiele przykładów zastosowania tej metody. Jednym z przykładów jest wykorzystanie jej w eksploracji sieci www. Polega ona na odkrywaniu interesujących zależności, reguł ukrytych w zbiorach sieci www, które stanowią repozytorium danych nieustrukturalizowanych i sposób korzystania z nich.[66][50][67][49]. W związku z taką złożonością danych można wyróżnić kilka metod eksploracji sieci Web [66][50][67]: eksploracja zawartości sieci Web, eksploracja połączeń sieci Web oraz eksploracja korzystania z sieci Web.

Eksploracja tekstu opiera się o hipotezę Rijsbergena[68]: „*closely associated documents tend to be relevant to the same request*”, która można tłumaczyć tak, że podobne dokumenty znalezione do danego pytania mogą stanowić odpowiedź na to samo pytanie. Eksploracja tekstu polega na odkrywaniu wiedzy z tekstowych baz danych dotyczących wyszukiwania tekstów podobnych, analizie zawartości dokumentu i realizowana jest na wiele sposobów. Jednym z nich jest wyszukiwanie podobieństw w bibliografii oraz cytowań zastosowanych w tekście. Drugim sposobem jest porównywanie słów kluczowych dokumentu. Oba te sposoby są niewystarczające, ponieważ wiele dokumentów nie posiada bibliografii lub nie jest opisana słowami kluczowymi. Innym sposobem jest analiza treści dokumentu, opierająca się na prostych technikach wyszukiwania, zliczania i dopasowania „słów kluczowych” biorąc pod uwagę strukturę dokumentu. Gdyż słowa kluczowe powinny reprezentować tezy i zagadnienia dokumentu, a wątki poboczne i dygresje powinny zostać pominięte.

Odkrywanie wzorców sekwencji i podobieństw w przebiegach czasowych. Polega na odszukaniu czasowych wzorców np.: charakterystyki. W tego typu zagadnieniach wykorzystuje się transformatę Fouriera i transformatę Falkową.

Wykrywanie zmian i odchyłeń polega na znajdowaniu różnic pomiędzy aktualnymi a oczekiwanymi wartościami danych, czyli anomalii, odchyłeń i wyjątków w przebiegach czasowych opisujących określone procesy.

Zgodnie z założeniami proponowanej w niniejszej pracy metody odkrywania wiedzy oraz zgodnie z proponowanym sposobem jej wykorzystania w dalszej części pracy rozważane będą metody eksploracji pozwalające na jawną reprezentację odkrytej wiedzy w postaci reguł.

4.3 Regułowa reprezentacja wiedzy, rodzaje reguł

Regułowa reprezentacja wiedzy jest powszechnie uznawana za jedną z najczytelniejszych form zapisu wiedzy. W kontekście systemów informatycznych oraz systemów sztucznej inteligencji była ona stosowana już w latach sześćdziesiątych i siedemdziesiątych ubiegłego stulecia - Mycin [69][70], Dendral [69]. W istocie jednak reprezentacja regułowa jest szczególną realizacją systemów logicznych, znanych już od starożytności [71]. Reprezentacja regułowa swoją niesłabnącą popularność zawdzięcza ciekawej właściwości: jest czytelna dla człowieka a jednocześnie podatna na efektywne przetwarzanie komputerowe. Reguły cechuje modularność — stanowią osobne „porcje” wiedzy, które mogą być rozważane indywidualnie, jednocześnie zachowują zdolność swoistej interakcji w trakcie realizacji wniosku, pozwalając na prezentowanie czytelnych uzasadnień jego przebiegu [54][72].

Reguła jest zwykle nieformalnie zapisywana w sposób zbliżony do instrukcji warunkowej wykorzystywanej w językach programowania, albo z wykorzystaniem implikacji logicznej:

Jeżeli przesłanka **To** konkluzja

przesłanka \rightarrow konkluzja

Najpopularniejszą formą reguł jest postać nawiązująca do klauzuli Horna [72], w której konkluzja składa się z pojedynczego literału a przesłanka z n literałów połączonym funktorem koniunkcji logicznej:

Jeżeli p_1 **i** p_2 **i** ... **i** p_n **To** konkluzja

$p_1 \wedge p_2 \wedge \dots \wedge p_n \rightarrow \text{konkluzja}$

Literały występujące w przesłance i konkluzji reguły mogą mieć bardzo różną postać. Wykorzystuje się zapis w postaci zmiennych zdaniowych, predykatów, kombinacji atrybut-wartość, obiekt-atrybut-wartość, perceptów [72]. W niniejszej pracy zakłada się, iż źródłem danych dla eksploracji będzie system informacyjny, przekształcony do postaci tablicy decyzyjnej [73], opisywanej atrybutami symbolicznymi oraz numerycznymi. Reguły będące wynikiem eksploracji będą tworzone z wykorzystaniem literałów w postaci dwójek atrybut-wartość.

W niniejszej pracy rozważane są reguły generowane automatycznie na podstawie danych, co jest domeną uczenia maszynowego i eksploracji danych. Ważną kategorią reguł, rozpatrywanych w tej dziedzinie, są *reguły decyzyjne* (ang. *decision rules*). Część warunkowa reguły decyzyjnej zawiera koniunkcję warunków zbudowanych na atrybutach i wartościach atrybutów warunkowych [73] opisujących obiekty w eksplorowanym zbiorze danych, część decyzyjna zawiera atrybut decyzyjny wraz z jego wartością, para ta określa przynależność obiektu do danej klasy decyzyjnej. Reguły decyzyjne budowane dla określonego zestawu danych mają zatem zazwyczaj ten sam, wybrany atrybut decyzyjny w konkluzji.

Drugą ważną kategorią reguł są reguły *asocjacyjne* (ang. *association rule*). Odkrywanie reguł asocjacyjnych jak już wcześniej było zaznaczone wywodzą się z jednego ze sztandarowych zastosowań — analizy koszykowej. Z tego powodu opisy takich reguł (również formalne) często odwołują się do pojęć związanych z transakcjami [56]. Reguły asocjacyjne posiadają ogólną postać analogiczną do omówionej wyżej, przypominają zatem reguły decyzyjne. Jednak w przypadku reguł asocjacyjnych zarówno ich idea, jak i końcowa reprezentacja jest odmienna. Ich celem jest identyfikowanie powiązań występujących pomiędzy podzbiorami atrybutów, najczęściej powiązania te oznaczają często powtarzające się zależności pomiędzy atrybutami. Wejściowy zbiór danych zawiera opisy pewnych przypadków, przykładowo transakcji handlowych. Atrybuty oraz ich wartości opisują elementy występujące w analizowanych przypadkach — np. kupowane towary.

Reguły asocjacyjne przyjmują zwykle postać implikacji, przesłanka zawiera koniunkcję literałów (zwykle pary atrybut-wartość), konkluzja zawierać może również koniunkcję literałów. Reguła reprezentuje wiedzę, na temat tego, że łączne wystąpienie opisów w przesłanki implikuje łączne wystąpienie opisów z konkluzji. Konkluzja reguły asocjacyjnej nie zawiera zadanego atrybutu decyzyjnego, atrybut występujący w konkluzji jest odkrywany na etapie generowania reguł [56].

Podsumowując i uogólniając — klasycznie rozumiane reguły decyzyjne posiadają w konkluzji pojedynczy, z góry określony atrybut decyzyjny, oraz wartość, określającą do jakiej klasy decyzyjnej może być przydzielony obiekt, dla którego przesłanka reguły jest prawdziwa. Reguły asocjacyjne opisują zależności pomiędzy atrybutami oraz ich wartościami, określając, że wystąpienie przypadku, dla którego prawdziwa jest przesłanka reguły, pociąga za sobą wystąpienie opisu z konkluzji.

4.4 Reguły a wydobywanie wiedzy z obrazów cyfrowych

Niezależnie od rodzaju wykorzystywanych reguł — decyzyjnych czy asocjacyjnych — mogą one mieć dwojakie zastosowanie. Pierwsze z nich odpowiada celom każdego z rodzajów reguł — zwykle celem reguł decyzyjnych jest predykcja klasy decyzyjnej nowego obiektu, a celem reguł asocjacyjnych zidentyfikowanie powiązań pomiędzy cechami danych.

Drugie zastosowanie ma charakter bardziej ogólny. Oba rodzaje reguł mają charakter opisowy — są narzędziem opisu odkrytej, nowej, potencjalnie nieznanej wiedzy. Dzięki prostocie i czytelności reprezentacji regułowej, oba rodzaje reguł mogą stanowić narzędzie opisu wiedzy w całkowicie nieznanach dziedzinach, w których nie istnieją jeszcze uznane reguły opisujące wiedzę dziedzinową.

Zatem zastosowanie reguł decyzyjnych nie musi się ograniczać do zbudowania klasyfikatora, mogą one służyć do opracowania — potencjalnie złożonej — bazy wiedzy wspomagającej podejmowanie decyzji, nieograniczających się wyłącznie do zadań klasyfikacyjnych. W uogólnionym przypadku metody odkrywania reguł asocjacyjnych i decyzyjnych mogą się uzupełniać. Można rozważyć traktowanie ich jako rozwiązań alternatywnych albo stosowanych łącznie — przykładowo reguły asocjacyjne mogą stanowić interesujący etap preselekcji cech, które mogą pozwolić na wytypowanie atrybutu decyzyjnego, w sytuacji, gdy nie jest on znany.

Rozważania te nieformalnie nawiązują do dwóch koncepcji [52] złożonego systemu klasyfikacyjnego:

- *Systemu wielokrotnego*, który odnosi się do zbioru pojedynczych klasyfikatorów, których odpowiedzi są zagregowane do jednej odpowiedzi całego systemu klasyfikującego.

- *Systemu hybrydowego*, który odnosi się do systemu integrującego w fazie uczenia się przynajmniej dwa różne modele. System hybrydowy „dopasowuje się” do danych za pomocą wielu różnych reprezentacji.

W rozważanej w niniejszej pracy dwuetapowej metodzie odkrywania wiedzy w obrazach cyfrowych, uzasadnione i celowe wydaje się wykorzystanie obu rodzajów reguł. Seria obrazów cyfrowych bardzo często opisuje informacje o kolejnych obiektach — mogą to być obrazy reprezentujące typowe badanie obrazowe dla różnych pacjentów. Wiedząc jaka cecha ma charakter decyzyjny (klasyfikujący) w sensie diagnostycznym, dane wyekstrahowane z obrazów cyfrowych mogą posłużyć do wygenerowania reguł decyzyjnych, pozwalających na klasyfikowanie (bądź wspomaganie tego procesu) nowych przypadków.

Seria obrazów może jednak być wykorzystana inaczej. Załóżmy, że seria obrazów zawiera obrazy przedstawiające pewne zmiany chorobowe, a celem ich analizy jest odkrycie nieznanych powiązań pomiędzy elementami zawartymi w obrazach (np. obiektami, ich wielkością, kształtem, kolorami). Każda z cech owych elementów posiada odpowiednią interpretację diagnostyczną, a pochodzenie obrazów (w sensie identyfikacji pacjentów) nie jest istotne. Zastosowanie podejścia pozwalającego na odkrywanie reguł asocjacyjnych może pozwolić na odkrycie wielu potencjalnie interesujących powiązań, które ze względu na ich liczbę, czy poziom szczegółowości, mogą być trudne do wykrycia innymi metodami.

Oba rodzaje reguł są zatem interesujące z punktu widzenia proponowanej metody. Istotnym problemem jest dobór metodyki generowania reguł. Istnieje szereg różnych podejść do zagadnienia indukcji reguł decyzyjnych i asocjacyjnych. W ramach niniejszej pracy nie jest możliwe uwzględnienie wielu podejść, nie pozwalają na to ramy pracy, harmonogram jej realizacji oraz względy implementacyjne — proponowana metoda ma zostać zaimplementowana w systemie zdolnym do funkcjonowania w warunkach rozwiązywania rzeczywistych problemów. Następny rozdział poświęcony jest dyskusji ukierunkowanej na wybór konkretnej metodyki eksploracji danych wydobytych z obrazów cyfrowych.

4.5 Dobór metodyki generowania reguł

W rozważanym zagadnieniu ekstrakcji wiedzy z obrazów cyfrowych należy uwzględnić specyfikę danych wejściowych. Dane te pochodzą z obrazów cyfrowych, charakteryzując wybrane informacje o charakterze ilościowym lub jakościowym. Istnieje szereg obiektywnych i niemożliwych do wyeliminowania niedoskonałości analizowanych obrazów cyfrowych, które mogą, i zazwyczaj mają, wpływ na dane dla eksploracji.

Dane te mogą być *niepełne* — seria obrazów może zawierać takie, dla których wydobywanie zakładanych cech nie będzie możliwe np. ze względu na niedoskonałości procesu rejestracji obrazu. Dane mogą być *niespójne* — jednakowe, lub zbliżone opisy obiektów lub przypadków mogą prowadzić do różnych kategoryzacji, przykładowo obrazy o identycznym opisie mogą być zaliczane do różnych klas decyzyjnych. Niedoskonałość danych może wynikać z różnych przyczyn, mogą być nimi zarówno niedoskonałości rejestratorów, niesprzyjające warunki rejestracji samych obrazów, kumulujące się zniekształcenia będące wynikiem zastosowania metod analizy obrazów, błędy zaokrągleń obliczeń, dyskretyzacji danych ciągłych. Niedoskonałości danych mogą mieć również przyczynę generyczną, i być wynikiem niespójności i niejednoznaczności wiedzy dziedzinowej, niejednoznaczności interpretacyjnych, rozbieżnych opinii ekspertów dziedzinowych.

Rozważana w pracy metoda eksploracji danych powinna uwzględniać wskazane niedoskonałości danych i oferować metody rozwiązywania związanych z tym problemów. Metodą spełniającą takie warunki jest metoda bazująca na teorii zbiorów przybliżonych (ang. *rough sets*), zaproponowanej przez profesora Zdzisława Pawłaka [9][72][73]. Teoria zbiorów przybliżonych dostarcza spójnych podstaw teoretycznych oraz metodologicznych dla sygnalizowanych problemów związanych z odkrywaniem wiedzy w obrazach cyfrowych.

Teoria zbiorów przybliżonych w sposób formalny opisuje dane wejściowe, definiując pojęcia systemu informacyjnego oraz tablicy decyzyjnej [73]. Opis ten idealnie odpowiada założeniom metody proponowanej w pracy. Rozważane podejście pozwala również na analizę istotności atrybutów i ich redukcję, dostarczając koncepcji atrybutów niezależnych/zależnych, jądra oraz reduktów [74]. Teoria zbiorów przybliżonych pozwala na analizę danych niedeterministycznych, wprowadzając koncepcję przybliżenia dolnego, górnego i brzegu zbioru, pozwala na usuwanie

niespójności w danych z wykorzystaniem metod ilościowych i jakościowych [10]. Odpowiada to problemom zidentyfikowanym na styku analizy obrazów oraz eksploracji danych. Ostatecznie na gruncie teorii zbiorów przybliżonych zdefiniowano wiele metod generowania reguł decyzyjnych oraz asocjacyjnych [75][76]

Metody bazujące na teorii zbiorów przybliżonych zostały z powodzeniem zastosowane w wielu dziedzinach, dowodząc praktycznej skuteczności tego podejścia (m.in.: [77][78][75]) oraz pozwoliły na realizację skutecznych narzędzi ogólnego przeznaczenia [76][79][80][81][82].

Wobec powyższego, podejście eksploracyjne bazujące na teorii zbiorów przybliżonych zostanie przyjęte jako podstawowa metoda realizacji drugiego etapu proponowanej metody ekstrakcji wiedzy z obrazów cyfrowych.

5 Podstawy teorii zbiorów przybliżonych

Teoria zbiorów przybliżonych opracowana przez Zdzisława Pawlaka [9][12], dostarcza narzędzi matematycznych do formalnego opisu wiedzy, w tym wiedzy niepełnej i niedokładnej. Wykorzystywana jest skutecznie m.in. w eksploracji danych i odkrywaniu wiedzy, złożonych zadaniach klasyfikacji oraz w komputerowych systemach wspomagania decyzji. Rozdział ten zawiera przegląd wybranych zagadnień teorii zbiorów przybliżonych, powiązanych z koncepcją proponowanej w niniejszej pracy dwuetapowej metody ekstrakcji wiedzy z obrazów cyfrowych.

5.1 System informacyjny i relacja nierozróżnialności

Teoria zbiorów przybliżonych wykorzystuje pojęcie *systemu informacyjnego* oraz *systemu decyzyjnego*, nazywanego również tablicą *decyzyjną*. Wykorzystują one tablicowy sposób reprezentacji danych, gdzie kolumny są etykietowane przez atrybuty (parametry, własności, cechy), wiersze odpowiadają obiektom (elementom, sytuacjom, stanom), a na przecięciu wierszy i kolumn znajdują się wartości odpowiednich atrybutów dla poszczególnych obiektów. Taka postać danych jest dogodna do reprezentowania informacji o cechach obiektów identyfikowanych w obrazach cyfrowych.

System informacyjny to para $SI = (U, A)$, gdzie:

- U jest skończonym, niepustym zbiorem, zwanym uniwersum, przy czym elementy zbioru U nazywamy obiektami.
- A jest skończonym, niepustym zbiorem atrybutów (własności, cech), gdzie każdy atrybut $a \in A$ jest funkcją: $a: U \rightarrow V_a$, przy czym V_a jest zbiorem wartości a .

W systemie informacyjnym zakładamy, że wszystkie atrybuty należą do zbioru A i są one traktowane w jednakowy sposób. Szczególnym rodzajem systemów informacyjnych są systemy decyzyjne, określane również mianem *tablic decyzyjnych*. Systemy decyzyjne będą w tej pracy oznaczane skrótem SD . W systemach decyzyjnych wyodrębnia się przynajmniej jeden *atrybut decyzyjny*. Powszechnie wykorzystywana definicja tablicy decyzyjnej [74], definiuje ją jako dwójkę: $SD = (U, A \vee \{d\})$, gdzie d jest *atrybutem decyzyjnym* niezaliczanym do zbioru atrybutów A systemu. Atrybuty

$a \in A$ nazywamy atrybutami warunkowymi. Tak zdefiniowana tablica decyzyjna posiada pojedynczy atrybut decyzyjny. Rzeczywiście w wielu zastosowaniach teorii zbiorów przybliżonych zakłada się występowanie pojedynczego atrybutu decyzyjnego, choć można wykorzystywać systemy decyzyjne z większą liczbą atrybutów decyzyjnych. Ze względu na powiązanie koncepcji tablic decyzyjnych z regułami decyzyjnymi, zostaną one omówione w osobnym podrozdziale.

Proponowane podejście nie ogranicza zakresu wartości atrybutów — rozważane są zarówno atrybuty symboliczne jak i ciągłe, przy czym dla tych ostatnich przewiduje się realizację procesu dyskretyzacji [74][83].

Używając pojęcia systemu informacyjnego można podać definicję relacji nierozróżnialności. Niech $SI = (U, A)$ będzie systemem informacyjnym i niech $B \subseteq A$. W zbiorze U definiujemy dwuargumentową relację $IND(B)$, generowaną przez zbiór B zwaną relacją nierozróżnialności (ang. *indiscernibility relation*), w następujący sposób:

$$IND(B) = \{ (x, y) \in U \times U : \forall a \in B, a(x) = a(y) \}, \quad (5.1)$$

gdzie: znak „=” między $a(x)$ i $a(y)$ oznacza, że dla obiektów x i y , należących do uniwersum U , atrybut a przyjmuje taką samą wartość.

Powyższa definicja opiera się na założeniu, że dla danych dwóch obiektów można jednoznacznie stwierdzić, czy obiekty te mają równe wartości dla zadanego atrybutu, czy też nie mają równych wartości. $IND(B)$ jest relacją równoważnościową, która spełnia następujące warunki:

1. Jest to relacja zwrotna, czyli:

$$\forall x \in U (x IND(B) x). \quad (5.2)$$

2. Jest to relacja symetryczna, czyli:

$$\forall x, y \in U: (x IND(B) y) \Leftrightarrow (y IND(B) x). \quad (5.3)$$

3. Jest to relacja przechodnia, jeżeli $x, y, z \in U$, wtedy

$$\forall x, y, z \in U (x IND(B) y) \wedge (y IND(B) z) \Rightarrow (x IND(B) z). \quad (5.4)$$

gdzie: $x IND(B) y$ oznacza, że x jest w relacji $IND(B)$ z y , tzn. $\forall a \in B, a(x) = a(y)$.

Ponieważ relacja $IND(B)$ jest relacją równoważnościową, dzieli ona zbiór obiektów U na klasy abstrakcji $[U]/IND(B)$, które są rozłączne, niepuste i dają cały

zbiór U . Każda klasa abstrakcji relacji $IND(B)$ zawiera obiekty nierozróżnialne między sobą za pomocą atrybutów ze zbioru B .

Klasa abstrakcji dla obiektu x relacji $IND(B)$ zdefiniowana może być następująco:

$$[x]_{IND(B)} = \{ y \in U, \forall a \in B (a(x) = a(y)) \}. \quad (5.5)$$

5.2 Aproksymacja zbiorów

Kluczowym elementem teorii zbiorów przybliżonych jest pojęcie aproksymacji zbiorów. W systemach informacyjnych oraz tablicach decyzyjnych próbuje się na podstawie przynależności obiektów do pewnych klas nierozróżnialności wnioskować o ich przynależności do pewnego pojęcia. Klasyczne podejście stosowane w systemach informacyjnych, wykorzystuje standardowe definicje teoriomnogościowe zbioru, posiada wady uniemożliwiające efektywne wnioskowanie na podstawie danych empirycznych. Klasyczny rachunek zbiorów wykorzystuje pojęcia ostre - element należy do zbioru lub nie. W warunkach rzeczywistych znaczna część pojęć nie jest definiowalna z wykorzystaniem klasycznej teorii zbiorów, co jest zwykle spowodowane niedokładnością danych i koniecznością wykorzystania pojęć nieostrych — w rzeczywistości bardzo często pewien obiekt może być zaklasyfikowany do pewnego pojęcia tylko w pewnym stopniu. Teoria zbiorów przybliżonych [12][84] oferuje mechanizm teoriomnogościowy pozwalający na ścisłe i formalne rozumowanie operujące na nieprecyzyjnych danych. Pomocne okażą się tutaj górne i dolne aproksymacje (przybliżenia) zbioru.

Jeżeli $SI = (U, A)$ jest systemem informacyjnym, $B \subseteq A$ jest zbiorem atrybutów oraz $X \subseteq U$, wówczas można zdefiniować pojęcia górnego i dolnego przybliżenia. Dla każdego obiektu $x \in U$, przez $[x]_{IND(B)}$ oznaczamy klasę abstrakcji relacji $IND(B)$, do której należy obiekt x .

Definicja - Dolnym przybliżeniem X w systemie informacyjnym SI nazywamy zbiór tych klas abstrakcji relacji nierozróżnialności, które całkowicie zawarte są w zbiorze:

$$\underline{B}X = \{x \in U: [x]_{IND(B)} \subseteq X\}, \quad (5.6)$$

co można również zapisać również:

$$\underline{B}X = \cap \{ Y \in U/IND(B) : Y \subseteq X \}. \quad (5.7)$$

Dolne przybliżenie X w SI jest największym definiowalnym zbiorem w SI , zawierającym się w X . Inaczej $\underline{B}X$ jest sumą wszystkich tych zbiorów elementarnych, które mają część wspólną ze zbiorem X .

Definicja - Górnym przybliżeniem X w systemie informacyjnym S nazywamy zbiór tych klas abstrakcji relacji nierozróżnialności, które mają część wspólną ze zbiorem:

$$\overline{B}X = \{ x \in U : [x]_{IND(B)} \cap X \neq \emptyset \}, \quad (5.8)$$

co można również zapisać również:

$$\overline{B}X = \cap \{ Y \in U/IND(B) : Y \cap X \neq \emptyset \}. \quad (5.9)$$

Górne przybliżenie X w SI jest najmniejszym definiowalnym zbiorem w SI , zawierającym X . Inaczej $\overline{B}X$ jest sumą wszystkich tych zbiorów elementarnych, które mają część wspólną z X .

Definicja - Brzegiem zbioru X w systemie informacyjnym SI nazywamy zbiór, który jest różnicą górnego i dolnego przybliżenia zbioru:

$$BN_B(X) = \overline{B}X - \underline{B}X. \quad (5.10)$$

Zbiór $\underline{B}X$ jest zbiorem wszystkich elementów z U , dla których można z pewnością stwierdzić (opierając się na wiedzy reprezentowanej przez atrybuty z B), że są elementami zbioru X . Zbiór $\overline{B}X$ jest zbiorem elementów z U , co do których można stwierdzić jedynie (opierając się na wiedzy reprezentowanej przez atrybuty z B), że mogą należeć do X . Zbiór $BN_B(X)$ jest zbiorem elementów, które za pomocą wiedzy z B , nie mogą być z pewnością zakwalifikowane ani do X , ani do $-X$. Aproksymacje zbiorów będą miały istotne znaczenie przy rozpatrywaniu tablic niespójnych, co zostanie omówione w jednym kolejnych rozdziałów.

5.3 Istotność informacji, redukcja danych

W celu precyzyjnego i konkretnego opisu relacji pomiędzy obiektami występującymi w systemie informacyjnym, stosuje się redukcję liczby atrybutów opisujących owe relacje. Poszukuje się takich podzbiorów atrybutów, które zachowują

podział obiektów na klasy decyzyjne taki sam, jak wszystkie atrybuty. Pozwala to analizować informacje używając potencjalnie mniejszej liczby atrybutów (podzbioru $B \subseteq A$). Takie zbiory atrybutów nie mogą być wyznaczone w dowolny sposób. W teorii zbiorów przybliżonych wykorzystuje się koncepcję *reduktu* będącego niezależnym podzbiorem atrybutów zachowującym taki sam podział na klasy decyzyjne jak wszystkie atrybuty rozważane w systemie. Węższym pojęciem jest pojęcie *jądra*, określającego zbiór atrybutów niezbędnych dla zachowania rozróżnialności obiektów w systemie.

W celu zdefiniowania jądra i reduktów w systemie informacyjnym, rozważmy następujące pojęcia. Niech $SI = (U, A)$ będzie systemem informacyjnym. Niech $B \subseteq A$ i $a \in B$. Mówimy, że atrybut a jest *zbędny* w B , gdy $IND(B) = IND(B - \{a\})$. W przeciwnym przypadku atrybut a jest *niezbędny* w B . Zbiór atrybutów B jest *niezależny*, gdy dla każdego $a \in B$ atrybut a jest niezbędny. W przeciwnym przypadku zbiór jest *zależny*.

Redukt

Podzbiór atrybutów $B \subseteq A$ nazywamy *reduktem* zbioru atrybutów A , gdy zbiór atrybutów B jest niezależny oraz $IND(B) = IND(A)$. Zbiór wszystkich reduktów oznaczamy przez $RED(A)$.

Redukt to najmniejszy zbiór atrybutów, przy którym zostaje zachowana dotychczasowa klasyfikacja (rozróżnialność) obiektów w systemie.

Jądro

Zbiór wszystkich niezbędnych atrybutów w B nazywamy *jądrem* (*rdzeniem*) i oznaczamy przez $CORE(B)$.

Pomiędzy jądrem a reduktem istnieje następujący związek:

$$CORE(B) = \cap RED(A), \quad (5.11)$$

gdzie: $RED(A)$ – zbiór wszystkich reduktów B , co oznacza, że jądro jest częścią wspólną reduktów.

Jądra i redukty dla systemu informacyjnego mogą zostać wygenerowane wprost na podstawie przedstawionych definicji. Drugim sposobem generacji jądra i reduktów jest wyznaczenie tych elementów z macierzy rozróżnialności $M(S)$.

Macierzą rozróżnialności dla danego systemu informacyjnego $SI = (U, A)$, gdzie $U = \{x_1, \dots, x_n\}$, nazywamy macierz $M(S) = [c_{ij}]_{n \times n}$ określoną w następujący sposób:

$$c_{ij} = \{a \in B : a(x_i) \neq a(x_j), i, j = 1..n\}. \quad (5.12)$$

Jak widać z powyższej definicji elementami macierzy są zbiory atrybutów, za pomocą których rozróżniane są dane obiekty.

Należy również zwrócić uwagę na następujące założenia:

$$\forall_{i,j=1..n} c_{ij} = c_{ji}, \quad (5.13)$$

$$\forall_{i=1..n} c_{ii} = \emptyset, \quad (5.14)$$

co oznacza, że macierz jest symetryczna, a na jej przekątnej elementy są zbiorami pustymi. Fakt ten jest przydatny przy implementacji tablicy rozróżnialności, gdyż dzięki niemu można zmniejszyć rozmiar pamięci potrzebnej do przechowywania tej tablicy.

W przypadku macierzy rozróżnialności *rdzeń* (ang. *core*) jest definiowany jako zbiór wszystkich pojedynczych elementów w macierzy.

$$CORE(A) = \{a \in A : c_{ij} = (a), \text{ dla dowolnych } i, j\}. \quad (5.15)$$

Zbiór $B \subseteq A$ jest *reduktem* w A wtedy i tylko wtedy, gdy B jest minimalny (w sensie zawierania się zbiorów) oraz z każdym niepustym elementem macierzy nieodróżnialności ma niepuste przecięcie.

$$B \cap c \neq \emptyset \text{ dla niepustych } c (c \neq \emptyset) \text{ w } M(A). \quad (5.16)$$

Oznacza to, że redukt jest najmniejszym zbiorem atrybutów, przy którym zostaje zachowana dotychczasowa rozróżnialność wszystkich obiektów.

5.4 Tablice decyzyjne

We wielu zastosowaniach praktycznych istnieje potrzeba podejmowania decyzji (i podejmowania ewentualnych akcji) w zależności od pewnych, obserwowanych czynników. Czynniki te mogą być opisywane za pomocą wartości atrybutów symbolizujących znane własności pewnych obiektów. Podejmowane decyzje także mogą być identyfikowane przy pomocy określonych atrybutów oraz ich wartości. W ten sposób bazując na systemie informacyjnym otrzymujemy narzędzie do modelowania

i symulacji procesów podejmowania decyzji [85][86]. Pojęcie *tablicy decyzyjnej* spotkać można w wielu dziedzinach zastosowań, również w rozpoznawaniu obrazów (atributami są tu wybrane cechy obserwowanego obiektu, decyzją – klasa, do której obiekt należy). Klasyczne zastosowania to systemy ekspertowe (np.: medyczne, atrybuty – objawy chorobowe, decyzja – diagnoza), do systemów sterujących układami fizycznymi (atributy – stan czujników, decyzja – wartości sterujące).

Tablica decyzyjna [9] jest to specjalna forma tablicy z zakodowanym zbiorem reguł decyzyjnych w oparciu o specyficzny, prosty do zidentyfikowania zbiór warunków i wynikających z nich czynności. Tablica decyzyjna może być przedstawiona w postaci, zaprezentowanej poniżej.

Tabela 1 Tablica decyzyjna

| Numer reguły | Atrybuty warunkowe | | | | | Atrybuty decyzyjne | | | | |
|--------------|--------------------|-----|-------------|-----|-------------|--------------------|-----|-------------|-----|----------------|
| | c_1 | ... | c_j | ... | c_k | d_1 | ... | d_j | ... | d_n |
| 1 | $v_{c_1}^1$ | ... | $v_{c_j}^1$ | ... | $v_{c_k}^1$ | $v_{d_1}^1$ | ... | $v_{d_j}^1$ | ... | $v_{d_n}^1$ |
| : | : | : | : | : | : | : | : | : | : | : |
| . | . | . | . | . | . | . | . | . | . | . |
| N | $v_{c_1}^N$ | . | $v_{c_j}^N$ | . | $v_{c_k}^N$ | $v_{d_1}^N$ | . | $v_{d_j}^N$ | . | $v_{d_n}^{1N}$ |

Każdy wiersz tablicy decyzyjnej reprezentuje regułę, która specyfikuje decyzje, jakie muszą być podjęte, gdy odpowiednie warunki zostają spełnione. Zbiory warunków i decyzji są przy tym określone przez wartości atrybutów warunkowych i decyzyjnych. Tak więc l -tą regułę decyzyjną, zawartą w tablicy decyzyjnej można zapisać następująco:

$$\textbf{\textit{Jeżeli}} \{c_1 = v_{c_1}^1 \ \& \dots \& \ c_k = v_{c_k}^1 \} \ \textbf{\textit{To}} \ \{d_1 = v_{d_1}^1 \ \& \dots \& \ d_n = v_{d_n}^1 \}.$$

Wcześniej w podrozdziale 5.1 przedstawiono definicję tablicy decyzyjnej. Można również przedstawić inną jej definicję [85]. Tablicą decyzyjną nazywamy uporządkowaną piątkę:

$$DT = \{U, C, D, v, f\},$$

gdzie: U, C, D są skończonymi zbiorami, v jest odwzorowaniem przyporządkowującym każdemu elementowi $a \in C \cup D$ skończony zbiór V_a , a f jest funkcją z $U \times (C \cup D)$ w sumę V zbiorów V_a taką, że $f(x, a) \in V$ dla wszystkich x oraz a .

Zbiór U nazywany jest *uniwersum* tablicy decyzyjnej, elementy C nazywane są *atributami warunkowymi*, elementy D nazywane są *atributami decyzyjnymi*, V_a jest *dziedziną* atrybutu a . Funkcja f nazywa się *funkcją decyzyjną*.

We wielu zastosowaniach praktycznych rozpatruje się tablice decyzyjne, w których zbiór atrybutów decyzyjnych D jest jednoelementowy. Mając tablice z wieloma atrybutami decyzyjnymi można zawsze przekształcić ją do tablicy z jednym atrybutem decyzyjnym, np. rozpatrując atrybuty warunkowe osobno z każdym atrybutem decyzyjnym. W dalszych rozważaniach rozpatrywane będą tablice decyzyjne z jednym atrybutem decyzyjnym. Poniżej przedstawiona jest przykładowa tablica decyzyjna

Tabela 2 Przykładowa tablica decyzyjna

| X | Atrybuty warunkowe (C) | | Atrybuty decyzyjne (D) |
|---|------------------------|----------|------------------------|
| | Wysypka | Gorączka | Diagnoza |
| 1 | N | T | Grypa |
| 2 | T | T | Ospa |
| 3 | T | N | Różyczka |
| 4 | N | N | Zdrowy |

Dla dalszych rozważań ważnym pojęciem jest *klasa decyzyjna tablicy decyzyjnej*. Jeśli $TD = (U, A \cup \{d\})$, jest tablicą decyzyjną oraz $v \in V_A$, to zbiór oznaczony przez X i zdefiniowany następująco: $X = \{x \in U : d(x) = v\}$, nazywamy klasą decyzyjną tablicy decyzyjnej T odpowiadającą wartości atrybutu decyzyjnego v . Natomiast dla dowolnego obiektu $u \in U$, przez $X(u)$ oznaczamy klasę decyzyjną $X_d(u)$. Do danej klasy decyzyjnej należą zatem wszystkie obiekty mające taką samą wartość decyzyjną.

5.5 Spójność tablicy decyzyjnej.

Niespójność jest bardzo istotnym problemem w systemach wspomagania decyzji. Usunięcie niespójności jest często jedynym sposobem na to, by bazując na wiedzy prezentowanej w danym systemie decyzyjnym, realizować procesy wnioskowania czy dokonywać klasyfikacji nowych przypadków.

Teoria zbiorów przybliżonych dostarcza metod usuwania niespójności i radzenia sobie z przypadkami opisanymi w przykładowej tablicy. Wyróżnić można 5 metod usuwania niespójności w tablicach decyzyjnych:

1. *Decyzja eksperta* — można zwrócić się do eksperta dziedzinowego, aby dla obiektów powodujących niespójność wskazał jedną decyzję. Jest to sposób

najprostszy przerzucający ciężar usunięcia niespójności z tablicy na eksperta. Niestety bardzo często zdarza się, że ekspert nie potrafi podjąć jednoznacznej decyzji bądź też wcale nie mamy dostępu do eksperta.

2. *Utworzenie kilku spójnych tablic decyzyjnych* — odbywa się to poprzez rozdzielenie sprzecznych obiektów. Jest to jednak tylko pozorne rozwiązanie problemu. Powstaną zbiory reguł każdej tablicy, złożenie reguł z tych źródeł doprowadzi do niespójności na poziomie reguł.
3. *Usunięcie obiektów* będących przyczyną niespójności metodą ilościową — metoda ta polega na pozostawieniu tego obiektu, dla którego istnieje większa liczba przypadków potwierdzających.
4. *Usunięcie obiektów* będących przyczyną niespójności metodą jakościową — usunięty zostaje ten obiekt, którego dokładność (górna lub dolna – w zależności od wyboru wariantu) jest mniejsza. Dla każdego $X \subseteq U$ i $B \subseteq A$ dokładność *dolnego przybliżenia* (γ_B) obliczamy ze wzoru:

$$\gamma_B(X) = \frac{|BX|}{|U|}. \quad (5.17)$$

Dokładność *górnego przybliżenia* (γ^B) obliczamy ze wzoru:

$$\gamma^B(X) = \frac{|\overline{BX}|}{|U|}. \quad (5.18)$$

1. Tworzenie nowego podziału systemu informacyjnego — decyzja d wyznacza klasyfikację:

$$\text{ClassA}(d) = \{X_1, \dots, X_{r(d)}\}, \quad (5.19)$$

gdzie: $r(d)$ – to ilość różnych wartości atrybutu decyzyjnego. Tworzymy nowy podział:

$$\text{App} - \text{ClassA}(d) = \{A_1, \dots, A_{r(d)}\} \cup \{Bd_A(\theta) : |\theta| > 1\}, \quad (5.20)$$

$$Bd_A(\theta) = \bigcap_{i \in \theta} BN_A(X_i) \cap \bigcap_{i \in \theta} \neg BN_A(X_i) \quad (5.21)$$

Ten nowy podział tworzy tablice decyzyjną spójną.

5.6 Reguły decyzyjne

Reguła decyzyjna, będąca nieodłączną częścią tablicy decyzyjnej [72][87][88], jest wyrażeniem opisującym zbiór warunków, które muszą być spełnione, aby został wykonany ciąg czynności.

Niech $U/IND(C)$ będzie rodziną wszystkich C -elementowych podzbiorów nazywanych *klasami warunkowymi*, oznaczonymi przez X_i , ($i=1, \dots, k$). Ponadto, niech $U/IND(D)$ będzie rodziną wszystkich D -elementowych podzbiorów nazywanych *klasami decyzyjnymi*, oznaczonymi przez Y_j , ($j=1, \dots, k$), wówczas $Des_C\{X_i\} \Rightarrow Des_D\{Y_i\}$ nazywamy *regułą decyzyjną*.

Reguła decyzyjna jest wyrażeniem logicznym postaci[89]:

JEŻELI koniunkcja warunków TO dysjunkcja decyzji.

Podzbiór reguł decyzyjnych dla wszystkich klas decyzyjnych Y_j , ($j=1, \dots, n$) jest oznaczany przez $\{r_{ij}\}$, gdzie:

$$\{r_{ij}\} = \{ Des_C\{X_i\} \Rightarrow Des_D\{Y_i\} : X_i \cap Y_i \neq \emptyset, i=1, \dots, k \}.$$

6 Metody ekstrakcji reguł decyzyjnych

Istnieje wiele metod generowania reguł, dotyczy to zarówno reguł decyzyjnych jak i asocjacyjnych. W niniejszym rozdziale przedstawiony zostanie krótki opis metod generowania reguł decyzyjnych i asocjacyjnych, istotnych w kontekście rozważanej problematyki.

6.1 Metody bazujące na teorii zbiorów przybliżonych

Metody oparte na teorii zbiorów przybliżonych wykorzystywane są do generowania reguł decyzyjnych pozwalają opisać wiedzę niepełną i niedokładną. Algorytmy bazujące na teorii zbiorów przybliżonych zostały wykorzystane w pracach [77][78][75], jak również w systemach analizy danych tj.: LERS [76][79], RSES [80], ROSETTA [81], GROBIAN [82].

6.1.1 Podejście trywialne

Tworzenie reguł decyzyjnych bazujące na teorii zbiorów przybliżonych zakłada, że źródłem danym będzie tablica decyzyjna $TD = (U, A \cup \{d\})$. Atrybut d jest pojedynczym atrybutem decyzyjnym, jego wartości wyznaczają klasy decyzyjne [73]. Zadaniem reguły decyzyjnej jest sklasyfikowanie obiektu do danej klasy decyzyjnej na podstawie wartości atrybutów warunkowych ze zbioru A . Zatem konkluzja (następnik) reguły decyzyjnej zbudowany jest tylko z pojedynczej formuły elementarnej, przesłanka (poprzednik) jest zbudowana z koniunkcji warunków elementarnych. Istnieje wiele metod generowania reguł decyzyjnych dla tak zdefiniowanej tablicy decyzyjnej. Intuicja podpowiada, że można utworzyć regułę decyzyjną dla każdego obiektu zapisanego w tablicy, tworząc przesłankę reguły jako koniunkcję par atrybut-wartość wszystkich atrybutów warunkowych, oraz konkluzję na podstawie wartości atrybutu decyzyjnego, odczytanej z tablicy. Takie reguły nazywane są *trywialnymi regułami decyzyjnymi*, i mogą być wykorzystane do stworzenia tzw. *trywialnego algorytmu decyzyjnego* [90]. Algorytm przeszukuje tablicę w poszukiwaniu wiersza tablicy posiadające wartości atrybutów warunkowych zgodne z klasyfikowanym obiektem, jeżeli taki wiersz zostanie znaleziony, obiekt zaliczany jest do klasy decyzyjnej wskazywanej przez wartość atrybutu decyzyjnego znalezionej wiersza.

Podejście to posiada dwie istotne wady. Po pierwsze dla tablic niespójnych otrzymamy różne decyzje dla takich samych warunków, o tym która decyzja zostanie podjęta decydować może przykładowo kolejność wierszy w tablicy lub kolejność jej przeglądu. Po drugie, w warunkach rzeczywistych, złożonych systemów klasyfikacyjnych, istnieje nikła szansa na znalezienie w tablicy wiersza, który na wszystkich atrybutach warunkowych będzie wykazywała zgodność z obiektem klasyfikowanym. Ta cecha reguł trywialnych skłania do poszukiwania reguł o mniejszej liczbie warunków elementarnych występujących w przesłance, zdolnych do klasyfikowania obiektów bez utraty jakości klasyfikacji.

W literaturze przedmiotu wskazuje się klasę reguł zwanych *regułami optymalnymi* [90]. Mają one taką własność, że z reguły optymalnej nie można już usunąć żadnego warunku elementarnego, gdyż spowoduje to spadek współczynnika dokładności reguły. Jednocześnie dodawanie kolejnych warunków elementarnych do poprzednika reguły optymalnej nie powoduje zwiększenia tego współczynnika. Istotną rolę odgrywają *reguły minimalne*, które dla każdej klasy decyzyjnej Y_i : (i) są regułami optymalnymi, (ii) dla każdego obiektu należącego do Y_i istnieje reguła wspierająca ten obiekt, (iii) odrzucenie dowolnej reguły ze zbioru minimalnego powoduje, że warunki (i) oraz (ii) przestają być spełnione [52]. Reguły minimalne zawierają zatem najmniejszą liczbę reguł decyzyjnych potrzebną do opisu wszystkich obiektów w tablicy. Istnieją podejścia ukierunkowane na poszukiwanie zbioru wszystkich reguł, które można wygenerować z danej tablicy – mówimy wtedy o indukcji *wyczerpującego zbioru reguł*. W niektórych przypadkach interesujące jest wyznaczenie tylko niektórych reguł decyzyjnych, spełniających pewne wymagane kryteria, mówimy wtedy o *satysfakcjonującym zbiorze reguł*. Taki rodzaj reguł jest czymś pośrednim pomiędzy regułami minimalnymi a wyczerpującym zbiorem reguł [52][90].

Teoria zbiorów przybliżonych dostarcza podstaw do sformułowania różnych podejść do generowania wskazanych powyżej reguł decyzyjnych, zoptymalizowanych w stosunku do wskazanego wcześniej podejścia trywialnego. Materiały źródłowe opisują wiele metod oraz konkretnych algorytmów tworzenia reguł [52][90][91][74][10]. Dokładna ich analiza przekracza niestety ramy niniejszego opracowania, niżej zostały krótko przedstawione jedynie wybrane, najistotniejsze i najpopularniejsze algorytmy.

6.1.2 Generowanie nietrywialnych zbiorów reguł

Mimo różnorodności metod generowania reguł wskazać można wspólną dla wielu z nich koncepcję bazową — redukcję liczby warunków elementarnych oraz redukcję liczby reguł. Redukcja liczebności przesłanek reguł bardzo często bazuje na opisanej wcześniej koncepcji *reduktu* zbioru atrybutów.

Redukty zbioru atrybutów $A \cup \{d\}$ (oznaczane $RED(A \cup \{d\})$), pozwalają na znalezienie zależności decyzyjnych [92], które jednak mogą być zbyt szczegółowe, bowiem, klasycznie rozumiana relacja nierozróżnialności (5.1) rozróżnia pary obiektów, również tych, które należą do tej samej klasy decyzyjnej. W przypadku poszukiwania reguł decyzyjnych, różnice pomiędzy obiektami należącymi do tej samej klasy są nieistotne. Dlatego, przedstawiona [9][72].bazowa koncepcja reduktu znajduje szereg wersji zmodyfikowanych, nazywanych *reduktami uogólnionymi* [74]. Redukty uogólnione pozwalają na redukcję zbioru rozpatrywanych atrybutów m.in.: pod względem ustalonego obiektu $u \in U$, względem decyzji d , a także z uwzględnieniem obu tych zależności. W pracach [74][90] wskazuje się cztery typy reduktów, bazujące na różnie określanych relacjach nierozróżnialności. W sensie praktycznym wyznaczanie uogólnionych reduktów oparte jest na zmodyfikowanych macierzach nierozróżnialności.

Algorytmy obliczania reduktów tablicy decyzyjnej względem atrybutu decyzyjnego i ustalonego obiektu zostały wykorzystane do wyznaczania *optymalnych reguł decyzyjnych* [10][90]. Na mocy udowodnionych twierdzeń [90] można stwierdzić, że uzyskanie wszystkich reguł optymalnych dla danej tablicy decyzyjnej polega właśnie na wyznaczeniu reduktów względem decyzji dla wszystkich obiektów z osobna.

Proces wyznaczania reguł bazujących na reduktach względnych może być zrealizowany wieloma sposobami, najczęściej wykorzystywana metoda bazuje na wnioskowaniu boolowskim opartym na funkcjach rozróżnialności, zaproponowaną przez Skowrona [93]. Podejście bazujące na reduktach i wnioskowaniu boolowskim rozszerzane jest o stosowanie *reduktów przybliżonych* oraz *reduktów dynamicznych* [94]. Spowodowane jest to głównie tym, że w oryginalnej postaci rozważany problem poszukiwania minimalnego zbioru reguł jest problemem *NP-zupełnym* [90][93].

Jak już wcześniej wspomniano, generowanie reguł decyzyjnych może odbywać się różnymi metodami a otrzymane reguły mogą różnić się właściwościami. Podejścia

bazujące na regułach minimalnych ukierunkowane są na pokrycie zbioru wszystkich obiektów za pomocą minimalnego zbioru reguł. Istnieją podejścia ukierunkowane na poszukiwaniu zbioru wszystkich reguł w przyjętej składni, które można wygenerować z danej tablicy – mówimy wtedy o indukcji wyczerpującego zbioru reguł. Inna kategoria algorytmów generuje ograniczony zbiór wszystkich reguł spełniających pewne warunki, np.: minimalna liczba przykładów wspierających, maksymalna długość części warunkowej [91].

Algorytmy LEM1 i LEM2 [76][95][96] są jednymi z popularniejszych algorytmów generowania minimalnego zbioru reguł, który jest wykorzystywany w praktyce. Bazują one na idei lokalnego pokrycia, budują one minimalny zbiór reguł bazując na heurystykach charakterystycznych dla algorytmów uczenia maszynowego. Algorytmy LEM są relatywnie szybkie i niewymagające obliczeniowo. Algorytm LEM1 działa jedynie dla danych niesprzecznych, tzn. każde dwa obiekty uniwersum U , należące do różnych klas decyzyjnych, muszą być rozróżnialne poprzez wartości atrybutów warunkowych. Algorytm w każdym kroku sprawdza, czy możliwe jest usunięcie jednego atrybutu z analizowanego zbioru atrybutów, jeżeli tak jest, to atrybut jest usuwany ze zbioru atrybutów. W efekcie otrzymywany jest najmniejszy podzbiór atrybutów warunkowych zachowujący rozróżnialność obiektów z różnych klas. Algorytm LEM2 na wejściu otrzymuje aproksymacje rozpatrywanej klasy decyzyjnej, która może to być dolną aproksymacją, wtedy są generowane reguły pewne, lub może być górną, wtedy generowane są reguły prawdopodobne. Algorytm przy generowaniu każdej reguły bierze pod uwagę tylko te warunki, które są spełnione przynajmniej przez jeden obiekt z rozpatrywanego zbioru. W każdym kroku generowania reguły wybierany jest taki warunek, który jest spełniany przez największą liczbę obiektów. Gdy takich warunków jest więcej, spośród nich wybierany jest ten, który jest spełniony przez najmniejszą liczbę wszystkich obiektów z uniwersum. Po wygenerowaniu każdej reguły, następuje jej przycinanie poprzez usunięcie zbędnych warunków. Po wygenerowaniu wszystkich reguł, następuje przycinanie zbioru reguł poprzez usuwanie zbędnych reguł.

Kolejnym algorytmem jest MODLEM [91], przetwarzający bezpośrednio dane zawierające atrybuty liczbowe bez ich wcześniejszej dyskretyzacji. Algorytm uwzględnia wartości tych atrybutów podczas indukcji reguł w momencie poszukiwania najlepszych warunków elementarnych. Ogólny schemat poszukiwania reguł jest zbliżony do zasady generowania lokalnych pokryć stosowanej w algorytmie LEM2.

Algorytm MODLEM występuje w dwóch wersjach, MODLEM-Entropy oraz MODLEM-Laplace. W pierwszym do oceny warunków elementarnych użyto miary entropii warunkowej, w drugim przedstawiono alternatywną propozycję użycia estymaty Laplace'a. Algorytm MODLEM jest algorytmem heurystycznym generującym minimalny zbiór reguł, wykorzystywany sposób wyboru kolejnych warunków elementarnych w ogólności nie gwarantuje znalezienia optymalnego minimalnego zbioru reguł. Jednak badania eksperymentalne [52] wskazują, że zarówno liczba reguł, jak i liczba użytych warunków jest satysfakcjonująca.

Interesujące podejście generowania reguł decyzyjnych bazuje na koncepcji reduktów dynamicznych. Metody wykorzystujące takie redukty działają w dwóch krokach. Najpierw wyznacza się redukty dynamiczne o wysokim współczynniku stabilności a później dla każdego takiego reduktu wyznaczane są osobno obliczane reguły decyzyjne. Eksperymenty potwierdziły [94], że reguły decyzyjne wygenerowane dla reduktów dynamicznych radzą sobie dobrze z klasyfikacją nowych obiektów. Doprowadziło to do wykorzystania metod dynamicznej redukcji wiedzy (stosowanej przy wyznaczaniu reduktów dynamicznych) bezpośrednio do generowania reguł decyzyjnych. Podejście to bazuje na generowaniu wszystkich reguł optymalnych dla wybranej rodziny podtablic rozpatrywanej tablicy decyzyjnej. Tak generowane reguły nazywane są dynamicznymi i są to reguły optymalne dla jak największej liczby podtablic, należących do wybranej rodziny podtablic. Wyniki eksperymentalne [97][92] potwierdzają, że reguły dynamiczne są bardziej odporne na różnego rodzaju „zaburzenia” danych i mogą prowadzić do lepszej trafności klasyfikowania nowych obiektów.


Kolejna grupa metod, zakładająca tworzenie satysfakcjonującego zbioru reguł, wymaga wyspecyfikowania ograniczeń, które muszą spełniać reguły. Zwykle dotyczą one wartości wybranych miar oceny reguły. Generowanie reguł satysfakcjonujących realizowane jest zazwyczaj dwoma metodami. Pierwsza polega na odfiltrowaniu ze zbioru wszystkich reguł tych, które są interesujące wg pewnych kryteriów, zazwyczaj określonych przez użytkownika. Drugie podejście, wykorzystane przykładowe w algorytmie EXPLORE [91][52], polega na włączeniu do algorytmu ograniczeń dla poszukiwanego zestawu reguł. Ograniczenia te są kontrolowane przez wskazany warunek zakończenia algorytmu, który jednocześnie redukuje koszt obliczeniowy realizacji algorytmu.

Metody oparte na teorii zbiorów przybliżonych doczekały się szeregu implementacji, najbardziej znane to systemy LERS [76][79], RSES [80], ROSETTA [81], RoughDAS [98], RoughtFamily [99], GROBIAN [82].

Podsumowując, można stwierdzić, że metody bazujące na zbiorach przybliżonych oferują szereg interesujących algorytmów generowania reguł decyzyjnych. Mimo wskazania teorii zbiorów przybliżonych jako metodologicznej podstawy, oraz licznych do niej nawiązań, szereg algorytmów wykorzystuje rozwiązania zaczerpnięte z metod maszynowego uczenia oraz autorskie, oryginalne rozwiązania wykorzystujące ciekawe podejścia nie zawsze bezpośrednio związane ze zbiorami przybliżonymi. W sensie koncepcji generowania reguł decyzyjnych, za najistotniejsze osiągnięcia metod bazujących na teorii zbiorów przybliżonych można uznać spójną i konsekwentną koncepcję reprezentacji zbioru danych, redukcji wiedzy, rozstrzygania problemów z niespójnościami w danych. Istotnym walorem opisywanych metod jest osadzenie ich w dwóch kontekstach – kontekście budowania skutecznych klasyfikatorów nowych obiektów, oraz kontekście odkrywania wiedzy istotnej dla użytkownika systemu. W obu tych kontekstach podstawy oferowane przez zbiory przybliżone oferują spójność i elegancję formalną w warstwie metodologicznej oraz czytelność i skuteczność praktyczną.

6.2 Inne metody generowania reguł decyzyjnych

Selektywne pokrywanie. Generowanie zbioru reguł polega na tworzeniu pojedynczych reguł, z których każda pokrywa część zbioru trenującego i trwa do momentu pokrycia wszystkich przypadków trenujących. Podzbiór zbioru trenującego pokrywany przez część warunkową każdej reguły powinien zawierać przykłady tej samej kategorii lub przynajmniej z wyraźnie dominującą kategorią większościową [89]. Następnie ta jedyna lub dominująca kategoria przechodzi do części decyzyjnej reguły. Na rysunku przedstawiono schemat selektywnego pokrywania, gdzie okręgi reprezentują części warunkowe reguł, pokrywające w całości zbiór trenujący, natomiast czarne i białe okręgi są przykładami różnych kategorii.



Rys. 6.1 Schemat sekwencyjnego pokrywania[89]

Metoda selektywnego pokrywania doczekała się wielu modyfikacji. Te najlepiej znane i konkretyzujące opisaną powyżej metodę to systemy/algoritmy generowania reguł AQ oraz CN2. Algorytm AQ [100] był pierwszym opartym na metodzie selektywnego pokrycia. Jego podstawą do budowy hipotez jest „gwiazda” - specjalizująca maksymalnie ogólne złożone warunki pokrywające wybrany początkowy przykład pozytywny w celu odróżnienia ich od przykładów negatywnych. W pierwotnej postaci AQ tworzył minimalne opisy dyskryminujące pokrywające wszystkie przykłady. Algorytm ten był następnie rozwijany i wielokrotnie modyfikowany (AQ11, AQ15, AQ17). Zastosowano go również w systemie INLEN [101][102].

Algorytm CN2 [103] to połączenie idei AQ z drzewami decyzyjnymi, a jego celem jest lepsze uwzględnienie „zaszumionych” przykładów [89]. Stosuje też model tworzenia hipotez od tych najbardziej ogólnych do szczegółowych podobnie jak w algorytmie Itrule. Algorytm ten jest również rozwijany [104][105] i zaimplementowany w systemie MLC++. Wspomniany algorytm Itrule prowadzi do generowania reguł probabilistycznych.

Algorytm PRISM[106] opiera się na zasadzie kolejnych pokryć, natomiast HCV wykorzystuje macierze rozszerzeń. Znane są również algorytmy wykorzystujące zamianę drzewa decyzyjnego na reguły w postaci ścieżek od korzenia do liścia stanowiącego koniunkcję testów będących częścią warunkową reguły. Drzewa decyzyjne mogą być generowane za pomocą algorytmów ID3 lub C4.5.

Kolejną metodą generowania reguł decyzyjnych jest odkrywanie asocjacji, które polega na zbioru atrybutów z bazy danych pod kątem występowania w nich

powtarzających się zależności. Najpopularniejszym algorytmem generowania reguł asocjacyjnych jest algorytm Apriori [56], który przeszukuje zbiór danych D i w każdej kolejnej iteracji generuje rodziny coraz większych zbiorów częstych. Zbiory częste stanowią proste wzorce mówiące o tym, które elementy sensownie często występują. Działanie algorytmu kończy się, gdy nie można wygenerować już kolejnych zbiorów częstych a wynikiem jest suma k -elementowych zbiorów częstych.

6.3 Reguły asocjacyjne

Kolejną metoda generowania reguł jest odkrywanie asocjacji, które polega na analizie zbioru atrybutów z bazy danych pod kątem występowania w nich powtarzających się zależności. Najpopularniejszym algorytmem generowania reguł asocjacyjnych jest algorytm Apriori [56], który przeszukuje zbiór danych i w każdej kolejnej iteracji generuje rodziny coraz większych zbiorów częstych. Zbiory częste stanowią proste wzorce mówiące o tym, które elementy sensownie często występują. Działanie algorytmu kończy się, gdy nie można wygenerować już kolejnych zbiorów częstych a wynikiem jest suma k -elementowych zbiorów częstych.

Odmienne podejście do generowania zbiorów częstych zastosowano w algorytmie FP-Growth. Proces generowania reguł realizowany jest w dwóch krokach: początkowo na kompresji bazy danych D do postaci tzw. FP-drzewa, które stanowi ukorzeniony, etykietowany w wierzchołkach graf acykliczny, a następnie w drugim kroku do eksploracji FP-drzewa w celu znalezienia zbiorów częstych. Algorytm ten jest o rząd wielkości szybszy od algorytmu Apriori.

Podstawowym algorytmem odkrywania wzorców asocjacji jest algorytm GSP (ang. *Generalized Sequential Patterns*)[97]. Stanowi wersję rozszerzoną algorytmu Apriori dla danych sekwencyjnych i wykorzystuje własność monotoniczności wsparcia. Składa się z pięciu kroków: sortowanie bazy danych D w bazę sekwencji DS , znalezienie zbiorów częstych, transformację wyrazów sekwencji w listę zbiorów częstych zawierających się w tym wyrazie, znalezienie sekwencji częstych, a ostatnim krokiem opcjonalnym jest usunięcie wzorców sekwencji, które nie są maksymalne.

Do generowania wielopoziomowych reguł asocjacyjnych można wykorzystać algorytmy: Predictive Apriori, Tertius jak również prosty algorytm Apriori. Algorytm Predictive Apriori [98] łączy ufność i wsparcie w przewidywaną dokładność, poprzez

każdorazowe zwiększanie progu wsparcia, od którego zależy dokładność, i odnajduje najlepsze reguły asocjacyjne w ustalonym porządku.

We wstępnym etapie doboru metod eksploracji rozważanych w proponowanej metodzie, rozważano wykorzystanie reguł asocjacyjnych. Ostatecznie wybrano podejście bazujące na teorii zbiorów przybliżonych, ukierunkowane na generowaniu reguł decyzyjnych. Ponieważ reguły asocjacyjne wydawały się jednak interesującym środkiem opisu wiedzy zapisanej w danych, zdecydowano się na realizację eksperymentów związanych z generowaniem reguł asocjacyjnych dla serii obrazów, użytych do eksperymentów opisanych w rozdziale 8.1.

Eksperymenty przeprowadzono w środowisku systemu WEKA, oferującego różne algorytmy generowania reguł asocjacyjnych. Przeprowadzono eksperymenty z wykorzystaniem algorytmów Apriori, GeneralizedSequentialPatterns, PredictiveApriori, Tertius. Wyniki eksperymentów dla wykosztowanego zbioru danych stomatologicznych dowiodły dużą wrażliwość liczby jak i jakości generowanych reguł od samych algorytmów, jak i od parametrów owych algorytmów. Liczba wygenerowanych reguł w skrajnych przypadkach wahała się od 2 (algorytm Apriori), do 100 dla PredictiveApriori. Eksperti dziedzinowi wykazali duży dystans do otrzymanych rezultatów, wskazując raz oczywistość i naiwność pewnych asocjacji, w innych przypadkach zaś wskazując na ich doraźność. W obu przypadkach wskazano na niewielką istotność uzyskanej wiedzy.


Ocena ekspercka zadecydowała o pominięciu reguł asocjacyjnych w obecnym kształcie proponowanej w pracy metody. Nie zmienia to jednak domniemania, iż właśnie reguły asocjacyjne mogą być interesującym środkiem odkrywania wiedzy o charakterze nieprzewidywalnym, dokładniejsza analiza metod ich wykorzystania jest przewidywana jako następny etap prac badawczych. Wykrycie nowych prawidłowości opisujących współwystępowanie pewnych elementów obrazów cyfrowych może dostarczyć istotnej, wcześniej nieznanej wiedzy.

7 System implementujący dwuetapową metodę eksploracji danych graficznych

Celem niniejszego rozdziału jest przedstawienie opracowanej metody połączenia ekstrakcji cech wywodzących się z analizy obrazów z ekstrakcją danych, umożliwiającą generowanie reguł z danych graficznych uwzględniającą wiedzę i doświadczenie ekspertów dziedzinowych jak również weryfikację jej skuteczności na danych rzeczywistych.

7.1 Etap pierwszy — analiza obrazów

Sposób realizacji eksperymentów w wykorzystaniem zrealizowanego oprogramowania przedstawiono na serii obrazów dermatoskopowych nowotworu złośliwego – czerniaka uzyskanych we współpracy z AGH w Krakowie. Przykład badanego obrazu przedstawiono na rysunku Rys. 7.1.



Rys. 7.1 Obraz dermatoskopowy nowotworu skóry.

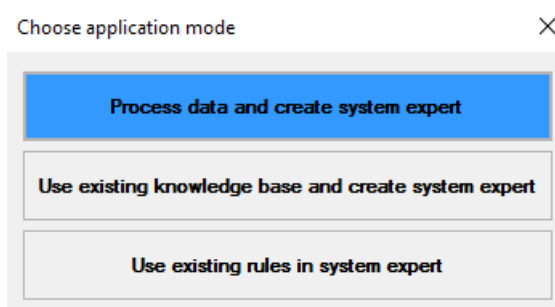
Zrealizowane oprogramowanie będzie prezentowane zgodnie z kolejnymi etapami proponowanej metody, etapem pierwszym jest importowanie i przetwarzanie obrazów (Rys. 7.2).



Rys. 7.2 Pierwszy etap pracy z systemem.

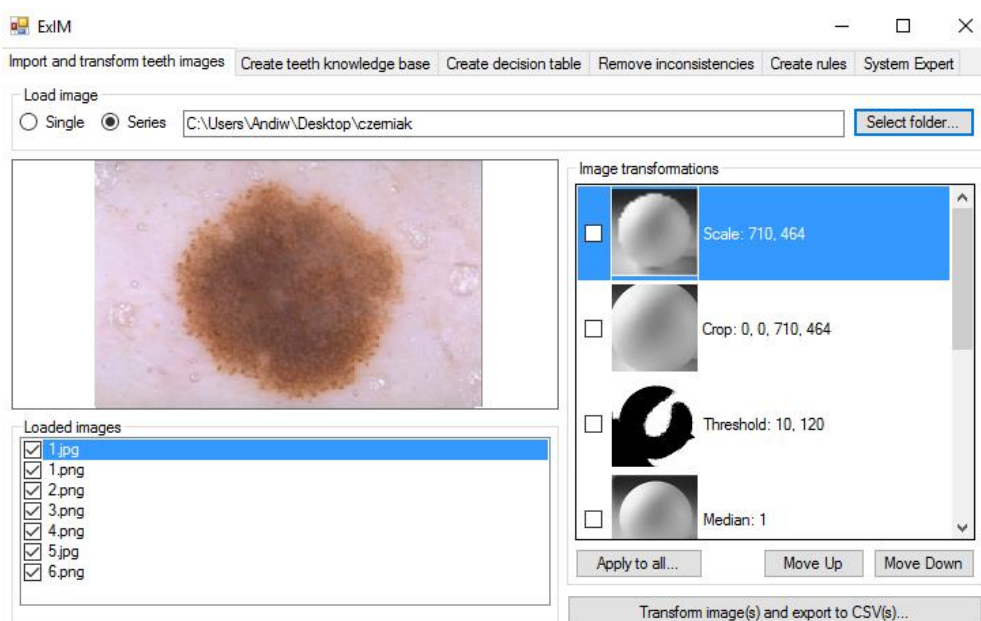
7.1.1 Ustalenie danych wejściowych

Uruchomienie oprogramowania rozpoczyna się od modułu *Choose application mode* (Rys. 7.3), w którym użytkownik dokonuje wyboru danych wejściowych. Zgodnie z założeniami, podstawowymi danymi wejściowymi jest seria obrazów cyfrowych, lecz zaproponowano również wykorzystanie dwóch dodatkowych opcji wyboru danych wejściowych. Oprócz serii zdjęć danymi wejściowymi mogą być bazy wiedzy w formacie.csv, lub reguły decyzyjne wygenerowane w formacie .txt. Rys. 7.3 przedstawia okno startowe aplikacji:



Rys. 7.3 Okno startowe aplikacji z możliwością wyboru danych wejściowych.

Po wybraniu standardowej opcji, w której danymi wejściowymi są obrazy cyfrowe uruchamia się okno *Import and transport images* przedstawione na Rys. 7.4. Moduł ten stanowi pierwszy krok pierwszego etapu metody realizowanym w systemie informatycznym.



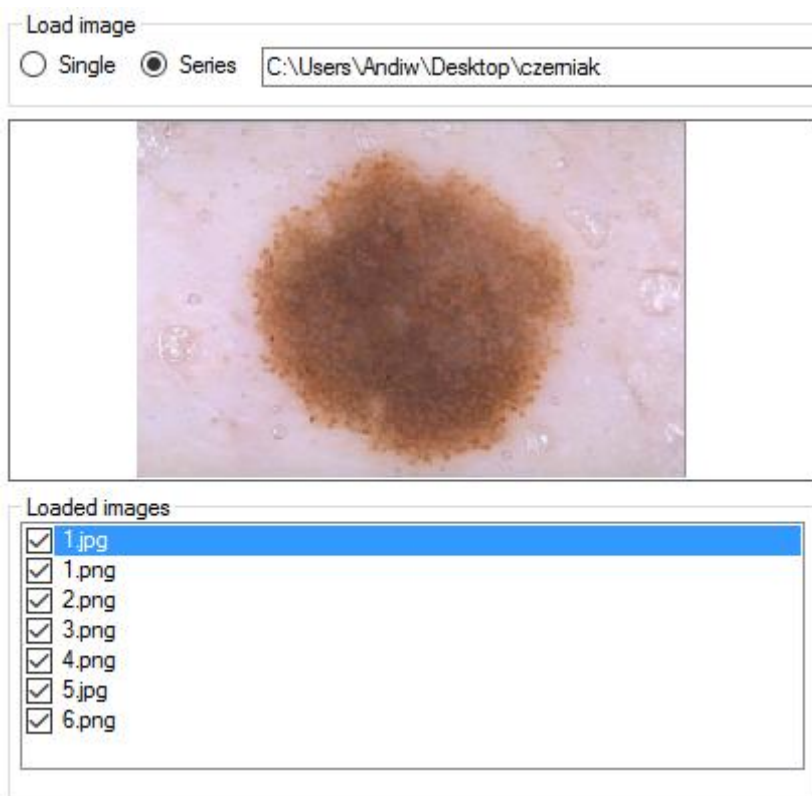
Rys. 7.4 Moduł Import and transform images.

Moduł *Import and transport images* odpowiada w pierwszej kolejności za wczytywanie oraz zarządzanie obrazami. Dzięki możliwościom HihgGUI w zakresie obsługi plików graficznych możliwe jest:

- Szybkie wczytywanie plików *Load image*, poprzez załadowanie pojedynczych obrazów *Single* lub całej serii zdjęć *Series* w przypadku, gdzie zdjęcia zarejestrowane są przy niezmiennych parametrach Rys. 7.5
- W części *Loaded images* Rys. 7.6 użytkownik zarządza kolejnością plików. Okno podglądu wyświetla wybór aktualnie modyfikowanego obrazu. Oznaczenie na liście pliki będą poddane modyfikacji w tym samym czasie. Domyślnie zaznaczone są wszystkie pliki.



Rys. 7.5 Wybór lokalizacji wczytywanych obrazów.



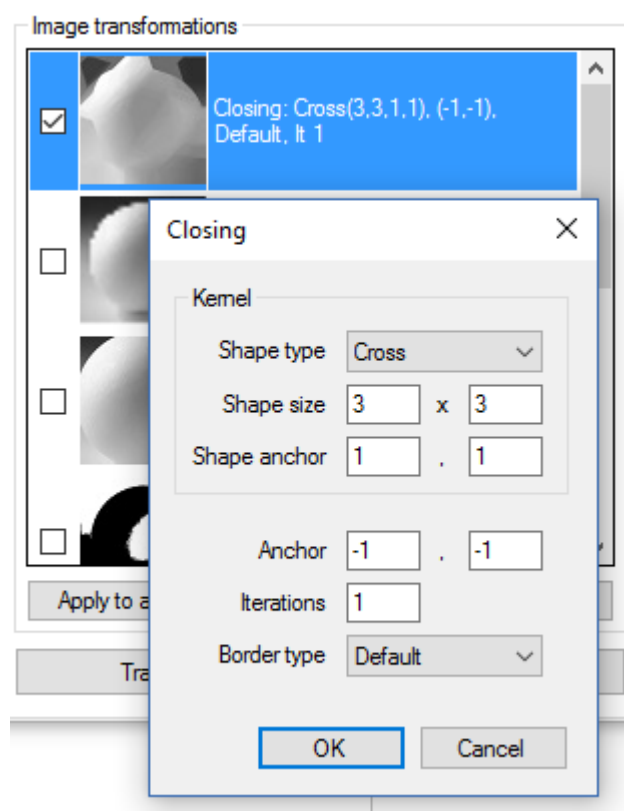
Rys. 7.6 Ładowanie obrazów — zarządzanie zdjęciami.

7.1.2 Wybrane elementy analizy obrazów

W części *Image transformation* znajdują się wyselekcjonowane algorytmy analizy i przetwarzania obrazu opisane w podrozdziale 3.4, wytypowane na podstawie wcześniejszej analizy literatury przedstawionej w rozdziale 3. Wybór operacji zatwierdzamy oznaczając pole po lewej stronie nazwy operacji. Każda z operacji posiada ikonę z widocznym wpływem danej operacji na obraz.

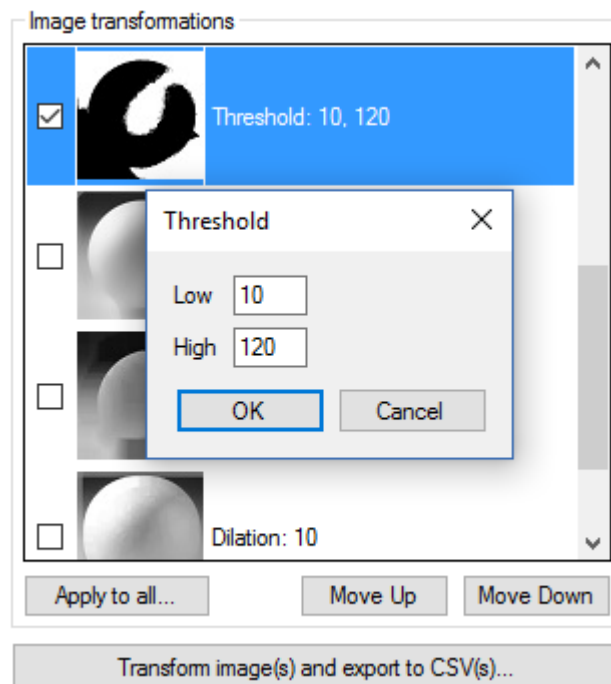
Modyfikacja parametrów wybranej operacji modyfikacji obrazu dostępna jest po dwukrotnym kliknięciu myszką - funkcje tworzące suwaki, przełączniki. Poniżej omówione zostały przykładowe operacje.

Operacja zamknięcia. Na Rys. 7.7 przedstawiono wybór operacji z oknem modyfikacji parametrów. W operacji zamknięcia można zdefiniować kształt obiektu, jego wielkość, zaczepienie czy rodzaj granicy. Standardowo użyto najczęściej stosowanych parametrów dla tej operacji.




Rys. 7.7 Operacja zamknięcia z opcją modyfikacji parametrów.

Operacja Progowania (Threshold). Na Rys. 7.8 przedstawiono wybór opcji progowania z możliwością ustawienia parametrów górnego oraz dolnego progu.



Rys. 7.8 Operacja Progowania z opcją modyfikacji parametrów.


Operacja Erozji. Na Rys. 7.9 przedstawiono operację erozji z możliwością ustawienia parametru.



Rys. 7.9 Ustawienie parametrów erozji.


Poniżej listy możliwych operacji przetwarzania obrazów umieszczono przyciski sterowania kolejnością wykonywania poszczególnych operacji. Za pomocą funkcji

Move Up oraz *Move Down* możliwe jest sterowanie kolejnością wykonywania poszczególnych operacji. *Apply to all..* umożliwia automatyczne zastosowanie wybranych operacji do całej serii zdjęć, lub tylko do tych oznaczonych w polu *Loaded Images*.



Rys. 7.10 Sterowanie kolejnością wykonywanych operacji analizy i przetwarzania obrazu.

W badanym przykładzie diagnozy czerniaka wykorzystano metodę ABCD służącą do określenia rodzaju deformacji znamienia. W tym celu badane obrazy poddano przetwarzaniu w celu uzyskania informacji dotyczących średnicy znamienia, jakości brzegów oraz koloru znamienia.



Rys. 7.11 Przetwarzanie obrazu czerniaka w celu uzyskania informacji o średnicy znamienia, jakości brzegów oraz koloru znamienia.

7.1.3 Prezentację wyników 1-go etapu

Informacje wyekstrahowane metodami przetwarzanych obrazów mogą być zapisane w pliku w formacie.csv, po kliknięciu *Transform image(s) and export to CSV(s)*. W pliku użytkownik ma możliwość sprawdzenia i modyfikacji uzyskanych wyników jak również uzupełnienia pewnych informacji jak również dodanie pozostałych atrybutów niewywodzących się z analizy przetworzonych zdjęć. Dla badanego przykładu diagnozy nowotworu złośliwego cztery atrybuty warunkowe pochodzą z analizy zdjęć dermatoskopowych, natomiast atrybut decyzyjny jest ustalony przez eksperta w dziedzinie onkologii.

We wczesnej diagnozie ognisk czerniaka wykorzystywana jest metoda ABCD(E) – *Asymmetry, Border, Colur, Diameter, Elevation*. Parametr *Asymmetry* określa nieregularne rozrośnięcie znamienia z jednej strony, *Border* określa stopień poszarpania brzegów znamienia, za zróżnicowanie zmian koloru, wybarwienia i nierównomierne rozmieszczenie barwnika odpowiada *Colur*. *Diameter* zawiera informację dotyczącą średnicy znamienia liczonej od 6 mm oraz wszelkie grudki, smugi i wybrzuszenia. Dodatkowym parametrem jest jeszcze *Elevation* określającą znaczną i nierównomierną wypukłość. W badanym przypadku parametr elevation został pominięty. Wartości poszczególnych parametrów zostały określone na podstawie metody przez lekarza onkologa.

Atrybuty warunkowe uzyskane w wyniku analiza obrazu:

- *Asymmetry* = {0,1,2}
- *Border* = {0,1,2,3,4,5,6,7,8}
- *Colur* = {1,2,3,4,5,6}
- *Diameter* = {1,2,3,4,5,6,7,8}

Atrybut decyzyjny określony przez eksperta - lekarza onkologa:

- *Diagnosis* = {tak, nie}

W wyniku wstępnego przetwarzania danych powstaje tablica decyzyjna stanowiąca podstawę do drugiego etapu analizy, ukierunkowanego na dobór metod przetwarzania danych, które pozwolą na odkrywanie i kodyfikacje wiedzy.

7.1.4 Prezentacja danych wejściowych dla etapu 2-go



Rys. 7.12 Drugi etap pracy z programem.

Drugi etap pracy z programem (Rys. 7.12) rozpoczyna się od modułu *Create decision table* pozwala wczytać plik.CSV do postaci tablicy decyzyjnej. Wejściowa tabela decyzyjna przedstawiona została na Rys. 7.13

ExIM

Create decision table Remove inconsistencies Create rules System Expert

Knowledge base file: Load knowledge base from file...

Knowledge base


| | Asymmetry | Border | Color | Diameter | Diagnosis |
|---|-----------|--------|-------|----------|-----------|
| ▶ | 0 | 8 | 2 | 2 | ni |
| | 1 | 4 | 3 | 2 | ni |
| | 2 | 5 | 4 | 4 | ta |
| | 0 | 0 | 2 | 2 | ni |
| | 2 | 3 | 4 | 4 | ta |
| | 2 | 3 | 4 | 4 | ta |
| * | | | | | |

Save knowledge base to file... ☒ Quality method ☐ Quantity method Remove inconsistencies

Rys. 7.13 Wejściowa tablica decyzyjna.

7.2 Etap drugi — eksploracja danych


7.2.1 Kontrola spójności



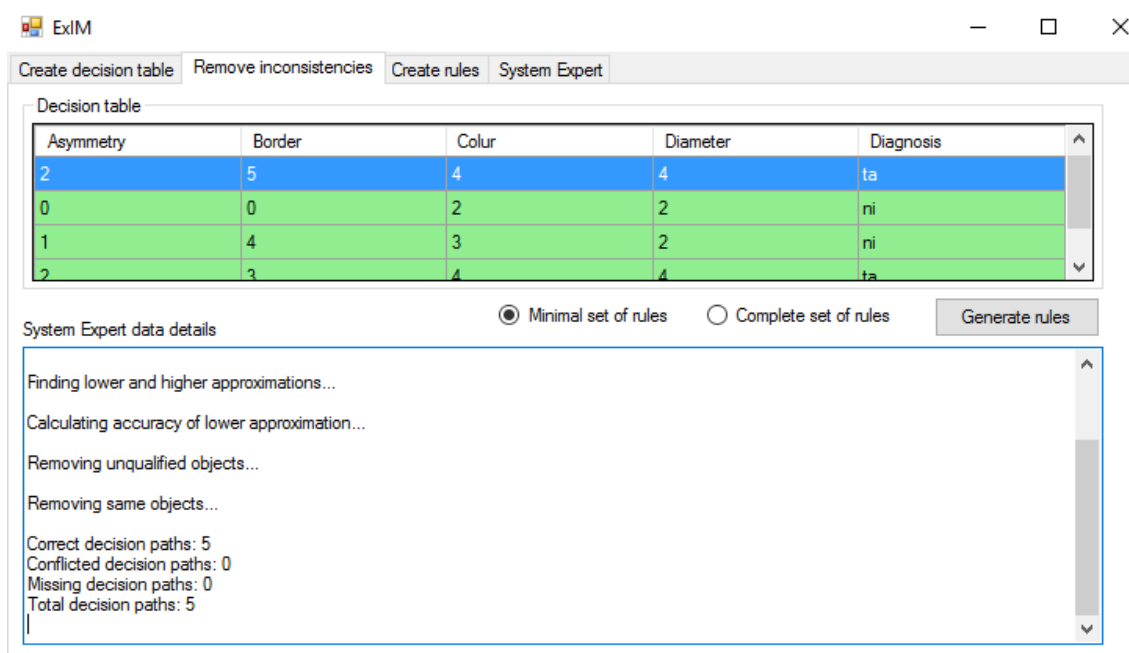
Rys. 7.14 Kolejny etap metody – usuwanie niespójności.

Przygotowana tablica decyzyjna zostaje następnie poddana badaniu spójności (Rys. 7.14). W module *Create decision table* usuwanie niespójności można wykonać dwoma zaimplementowanymi metodami: korzystającej z wiedzy eksperta – *Quantity* [9], *Quality method* (Rys. 7.15). Na Rys. 7.16 przedstawiono wynik usunięcia niespójności

metodą ilościową. Jeżeli obiekty zaznaczone są kolorem zielonym oznacza, że zostały poprawnie zaklasyfikowane.



Rys. 7.15 Wybór metody usuwania niespójności.



Rys. 7.16 Wynik usuwania niespójności metodą ilościową.

W przypadku równej liczby obiektów niespójnych, posiadających jednakową wartość atrybutu decyzyjnego (zaznaczone kolorem czerwonym), usunięcie niespójności zostało zrealizowane z udziałem ekspertów dziedzinowych. W przypadku decyzji o zmianie wartości atrybutu decyzyjnego przez eksperta – program umożliwia jego modyfikację po dwukrotnym kliknięciu komórki. Funkcja ta została zaprezentowana eksperymentach opisanych w podrozdziale 8.1.2 na Rys. 8.8.

Metoda ilościowa została uzupełniona funkcją wykrywania kombinacji atrybutów warunkowych, które nie wystąpiły w wejściowej tablicy decyzyjnej. Program wykrywa kombinacje atrybutów warunkowych, które nie były brane pod uwagę w wejściowej tablicy decyzyjnej. Obiekty te mogą zostać wykorzystane do generowania reguł tylko w przypadku uzupełnienia wartości atrybutu decyzyjnego przez eksperta.

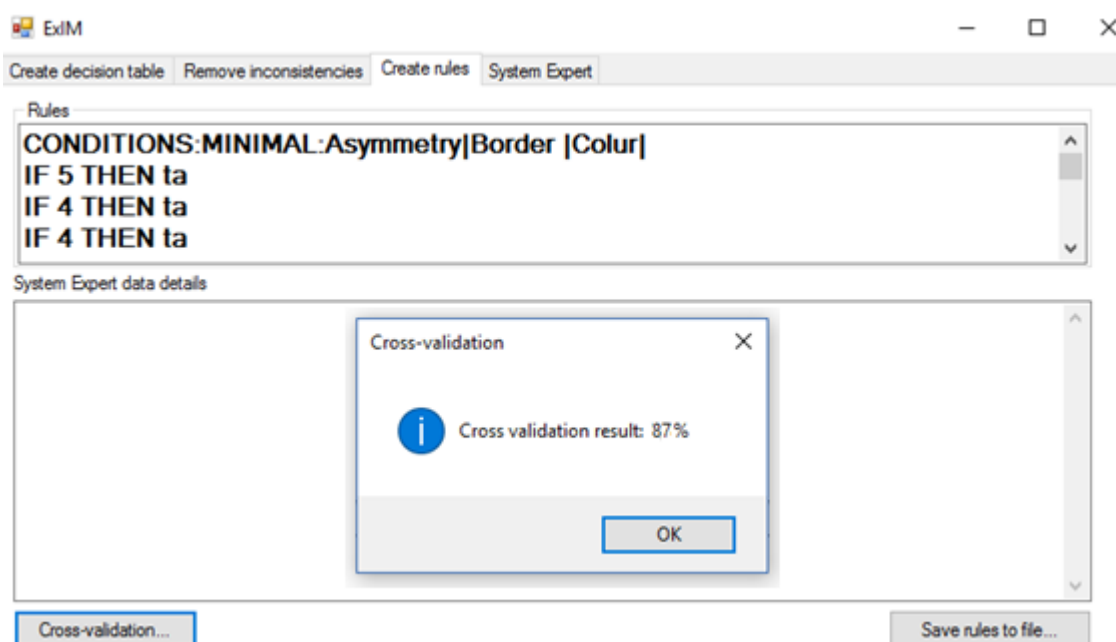
Metoda jakościowa opisana w podrozdziale 5.5 ma za zadanie usuniecie obiektu, którego posiada mniejszą dokładność dolnego i górnego przybliżenia. W przypadku analizowanego problemu po zastosowaniu metody jakościowej otrzymano identyczną liczbę obiektów.

7.2.2 Generowanie reguł




Rys. 7.17 Czarty etap pracy z programem.

Kolejnym krokiem jest praca w module *Create rules* przedstawionym na Rys. 7.18 wykorzystano metodę prostego generowania reguł dla każdego z obiektów tablicy (zgodnie z podrozdziałem 6.1.1), jak również alternatywnie algorytm generowania reguł minimalnych (zgodnie z podrozdziałem 6.1.2). Moduł ten uzupełniono możliwością weryfikacji otrzymanych reguł za pomocą walidacji krzyżowej. Wygenerowane reguły można eksportować do plików txt.



Rys. 7.18 Moduł Create rules.

7.2.3 Wykorzystanie reguł



Rys. 7.19 Ostatni etap pracy z programem.

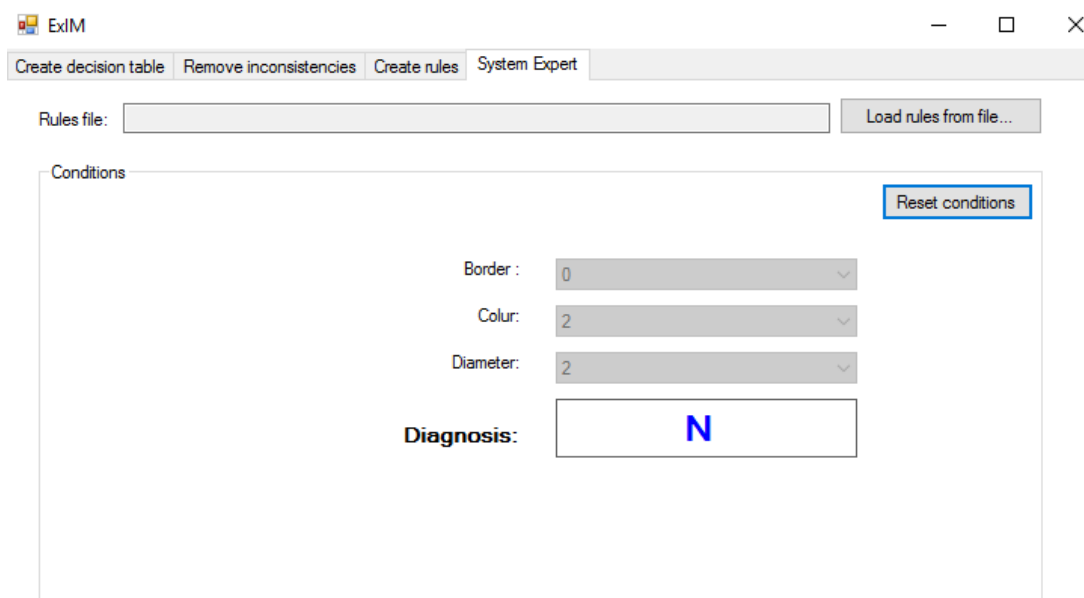
Ostatnim modulem (Rys. 7.19) oprogramowania jest *System Expert*, w którym otrzymane reguły służą do budowy prostego klasyfikatora z zastosowaniem wnioskowania w przód. Moduł ten umożliwia wczytanie reguł (Rys. 7.20) wcześniej wygenerowanych przez oprogramowanie jak również wykorzystanie reguł utworzonych w innym oprogramowaniu.



Rules file:

Rys. 7.20 Wczytywanie reguł

Wczytane reguły pozwalają na budowę klasyfikatora w części *Conditions*. Atrybuty warunkowe zostają wyświetlone wraz z listami rozwijanymi, które zawierają wartości atrybutów. Wybranie wszystkich wartości atrybutów warunkowych skutkuje wyświetleniem wartości atrybutu decyzyjnego zaznaczonego kolorem niebieskim. *Reset conditions* umożliwia ponowne wprowadzenie wartości atrybutów warunkowych dla nowo rozpatrywanego przypadku. Na Rys. 7.21 przedstawiono przykład odpowiedzi systemu.



ExIM

Create decision table Remove inconsistencies Create rules System Expert

Rules file:

Conditions

Border : 0

Colur: 2

Diameter: 2

Diagnosis: N

Rys. 7.21 Moduł System Expert z przykładem odpowiedzi systemu.

7.3 Zagadnienia implementacyjne

Dwuetapowa metoda ekstrakcji cech z obrazów cyfrowych została zaimplementowana w autorskim systemie informatycznym. Program został napisany przy użyciu języka C# w środowisku programistycznym Microsoft Visual Studio 2012. Oprogramowanie to zostało wybrane ze względu na szerokie możliwości projektowania aplikacji dla różnych systemów, czytelną pracę, zaawansowane debugowanie jak również monitorowanie przebiegu i testowanie aplikacji.

W module *Image transformation* dzięki implementacji biblioteki OpenCV (ang. *Open Source Computer Vision Library*), dostarczono narzędzia do przetwarzania obrazów. Biblioteka ta stała się niezwykle istotna ze względu na wysoką wydajność obliczeniową na potrzeby aplikacji czasu rzeczywistego. Napisana została w języku u C/C++ i wykorzystuje możliwości, jakie dają popularne od kilku lat procesory wielordzeniowe. OpenCV składa się z pięciu komponentów:

- CV oraz CVaux – komponenty zawierające funkcję transformacji, filtracji oraz konwersji przestrzeni obrazów, funkcję analizy obrazów takie jak selekcja, operacje morfologiczne, detekcję krawędzi oraz obsługę histogramów, detekcję obiektów, kalibrację kamery, rekonstrukcję sceny 3D i inne,
- MLL (ang. *Machine Learning Library*) - zawiera funkcje tworzenia klasyfikatorów bazujących na statystyce odgrywających znaczącą rolę w uczeniu maszyn sposobu detekcji,
- HighGUI – zawiera metody akwizycji i zwalniania obrazów, sekwencji wideo, narzędzia tworzenia interfejsu okienkowego, suwaków oraz obsługi myszy,
- CxCore – zawiera operacje na tablicach, algebrę macierzy, funkcje matematyczne, transformacje Fouriera, wsparcie dla plików XML, narzędzia rysowania obiektów 2D i inne.

Tworzenie Interfejsu użytkownika zebrane jest w bibliotece HighGUI (ang. *High-Level Graphical User Interface*), która zawiera funkcje OpenCV pozwalające na współdziałanie z systemem operacyjnym.

8 Badania i eksperymenty

Rozdział ten prezentuje proces realizacji badań, których celem jest weryfikacja skuteczności zaproponowanej metody na danych rzeczywistych. Dane pozyskano w wyniku współpracy z Pomorskim Uniwersytetem Medycznym w Szczecinie oraz Instytutem Spawalnictwa w Gliwicach, są to odpowiednio serie obrazów stomatologicznych oraz obrazy mikroskopowych złączy zgrzewanych metodą FSW. Wyniki opisywanych eksperymentów były konsultowane ze specjalistami z Uniwersytetu Medycznego oraz Instytutu Spawalnictwa.

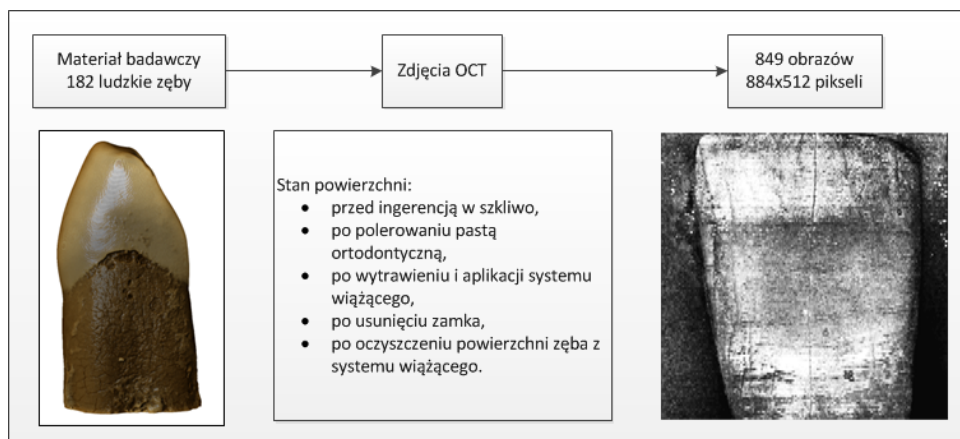
8.1 Obrazy stomatologiczne

Działanie dwuetapowej metody eksploracji danych pozyskanych z obrazów cyfrowych zostało przebadane dla problemu wspomagania decyzji lekarza stomatologa w zakresie podjęcia odpowiedniego leczenia ubytków szkliwa, powstałych po zdjęciu aparatu ortodontycznego. Dla potrzeb eksperymentów rozszerzono opisywany w poprzednim rozdziale system informatyczny o funkcje dedykowane dla tego właśnie zastosowania.

8.1.1 Etap pierwszy — analiza i przetwarzanie obrazów

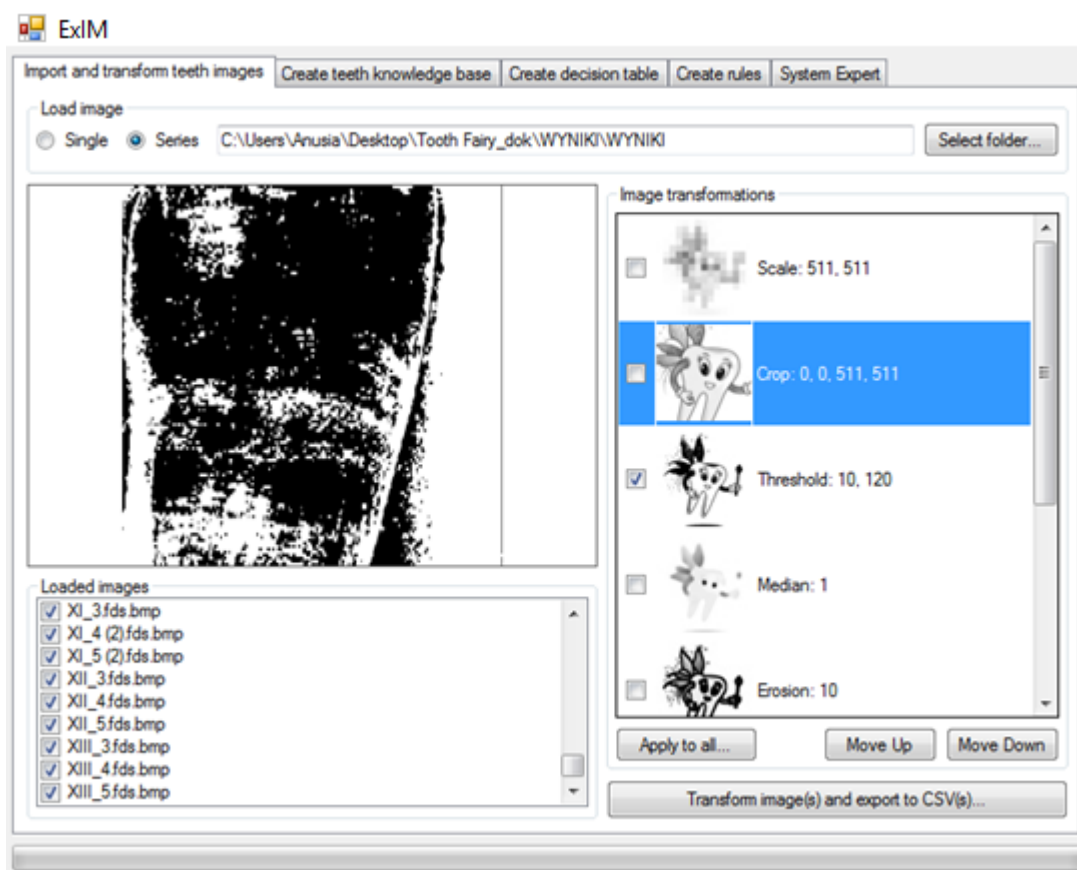
W pierwszym etapie badań materiałem wejściowym do procesu analizy obrazów jest seria zdjęć cyfrowych zębów zarejestrowanych za pomocą optycznego tomografu. Sposób pozyskania zdjęć do analizy obrazu został przedstawiony na Rys. 8.1.

Zarejestrowane obrazy posiadają rozmiar 884x512 pikseli. Pojedynczy piksel zajmował powierzchnię $5 \times 11,7 \mu\text{m}^2$. Wyodrębniono 849 obrazów, na których zarejestrowano stan powierzchni po przeprowadzeniu kolejno pięciu etapów leczenia: przed ingerencją w szkliwo, polerowanie pastą ortodontyczną, wytrawienie i aplikacja materiału wiążącego, przyklejenie zamka, usunięcie zamka, czyszczenie powierzchni zęba z materiału wiążącego. Rys. 8.1 przedstawia proces pozyskiwania zdjęć do dalszych badań.



Rys. 8.1 Proces pozyskania zdjęć.

Kolejnym krokiem było przetworzenie zdjęć opierając się na kombinacji podstawowych algorytmów analizy i przetwarzania obrazu tj.: filtracji, binaryzacji, zamknięcia, zalewania otworów i funkcji matematycznych (Rys. 8.2).



Rys. 8.2 Przetwarzanie zdjęć w module Import and transform images.

Początkowo obraz $L_{GRAY}=(m,n)$ poddano procesowi filtracji medianowej z maską o rozmiarze 7×7 . Rozmiar maski określono na podstawie wielkości występujących

szumów i artefaktów. Następnie na przefiltrowanych obrazach $L_M=(m,n)$ wykonano proces binaryzacji metodą Sauvola [109], która jest obecnie uważana za jedną z najlepszych metod analizy obrazu. Wartość progu ustalana jest na podstawie średniej oraz odchylenia standardowego wartości pikseli w bloku bezpośrednio otaczającym analizowany piksel.

$$T(m,n) = \mu(m,n) \left[1 + k \left(\frac{\sigma(m,n)}{R} - 1 \right) \right] \quad (8.1)$$

gdzie:

$T(m,n)$ – wartość progu dla piksela o współrzędnych (m,n)

$\mu(m,n)$ – średnia w otoczeniu piksela

$\sigma(m,n)$ – odchylenie standardowe w otoczeniu piksela

$k>0$ – parametr zależny od problemu


R – maksymalna wartość odchylenia standardowego, jakie może pojawić się w obrazie (dla obrazów o wartości pikseli $[0,255]$ przyjmuje wartość $R=128$).

Kolejnym krokiem jest wykonanie operacji morfologicznego zamknięcia na zdjęciach $L_{MB}=(m,n)$ z elementem strukturyzującym typu dysk o rozmiarze 5-7px.

$$L_C(m,n) = \min_{SE}(\max_{SE}(L_{MB}(m,n))), \quad (8.2)$$

gdzie: SE – element struktury o rozmiarze 5x7px, określony na podstawie średniej wielkości szumów.

Następnie usunięto wykonano operację zalewania otworów w wyniku której usunięto elementy o polu mniejszym od 100-150px. Efektem przeprowadzonych operacji jest ekstrakcja konturu zęba.



Rys. 8.3 a)obraz źródłowy b) wyekstrahowany kontur zęba.


Opierając się na wiedzy ekspertów z zakresu analizy obrazów i lekarza stomatologa do dalszej analizy został wybrany obszar zajmowany przez zamek ortodontyczny, co stanowiło obszar 100x100 centralnych pikseli (dla których odczytana została grubość szkliwa). W tym celu wyznaczono współrzędną x_1 będącej początkiem zęba (od lewej, przy założeniu, że ząb przesuwają się tylko prawo-lewo, jeśli nie jest na środku obrazu). Następnie wyznaczono współrzędną x_2 będącą końcem zęba (powielenie procedury wyznaczania współrzędnej x_1 z obróconym o 180 st. obrazem). Następnie wyznaczono środek zęba:

$$x_{sr} = \frac{(m - x_1 - x_2)}{2} \quad (8.3)$$

$$y_{sr} = \frac{n}{2} \quad (8.4)$$

Kolejnym krokiem było wyznaczenie kwadratu dla punktów:

$$(x_{sr} - 49, x_{sr} + 50, y_{sr} - 49, y_{sr} + 50) \quad (8.5)$$



Rys. 8.4 a) obraz źródłowy b) wyznaczenie centralnej powierzchni zęba.

Powyższe operacje wykonano dla każdego zdjęcia a wynikiem, jest 849 macierzy o rozmiarze $m \times n$ zawierających informację o grubości szkliwa dla poszczególnych etapów leczenia zapisane w pliku .csv.

Kolejnym etapem badań było usystematyzowanie wiedzy na temat czynników odgrywających istotną rolę w procesie przyklejenia zamka do szkliwa, a wpływających na powstawanie ubytków szkliwa (rodzaj powierzchni zęba i jej właściwe przygotowanie, budowa podstawy przyklejanego zamka, rodzaj ortodontycznego materiału łączącego). Pozwoliło to na wyodrębnienie informacji o charakterze danych

opisujących proces przyklejania zamka ortodontycznego jak i przygotowywania powierzchni zęba.

Dane wejściowe poddano wstępnemu przetworzeniu, które opisano czterema atrybutami warunkowymi:

- *Tooth Type* = {*Canine, Incisor, Premolar*}
- *Bracket Type* = {*Ceramic, Metallic, Composite*}
- *Adhesive System* = {*classic, Self Etching*}
- *Polishing Type* = {*Cutter, Elastic*}

oraz atrybutem decyzyjnym:

- *Damage*

Następnie przystąpiono do etapu standaryzacji wartości atrybutu decyzyjnego opartego na wiedzy ekspertów — osiągnięto to poprzez wykorzystanie formuły matematycznej dostarczonej przez stomatologów pozwalającej określić wielkość ubytku szkliwa $Damage = III: Avg - V: Avg$. Wyliczono średnie arytmetyczne, odchylenie standardowe oraz maksymalne i minimalne wartości grubości szkliwa dla każdego z przeprowadzonych etapów leczenia. Proces dyskretyzacji atrybutu decyzyjnego przeprowadzono bazując na wiedzy ekspertów. W tym celu określono trzy przedziały wartości ubytków, dla których powinno zostać podjęte leczenie. Wartości atrybutu decyzyjnego można opisać:

$$Damage = \{Small, Medium, High\} \quad (8.6)$$

Moduł przygotowania danych przedstawiono na Rys. 8.5

8.1.2 Drugi etap metody – ekstrakcja wiedzy

Wstępne przetwarzanie danych pozwoliło wyodrębnić 182 obiekty, które opisano czterema atrybutami warunkowymi, oraz atrybutem decyzyjnym - *Damage*.

W zbiorze 182 obiektów wykryto powtórzenia obiektów. Redukcja nadmiarowych obiektów wyodrębniła 60 unikatowych obiektów. Następnie przeprowadzono badanie spójności tablicy decyzyjnej. W module *Create decsion table* usuwanie niespójności przeprowadzona metodą ilościową.

ExIM

Import and transform teeth images Create teeth knowledge base Create decision table Remove inconsistencies Create rules System Expert

Data folder:

Starting column: Starting row: Data width: Data height:

Damage range: Small Medium High
 - - - ...

Computation details

| No. | I:Avg | I:Min | I:Max | I:StDev | II:Avg | II:Min | II:Max | II:StDev | III:Avg | III:Min | III:Max | III |
|-----|----------|-------|-------|------------|----------|--------|--------|------------|----------|---------|---------|-----|
| 1 | 719,0495 | 395 | 1260 | 177,551... | 475,47 | 185 | 1290 | 162,866... | 633,9135 | 255 | 1250 | 15 |
| 2 | 592,905 | 250 | 1475 | 194,935... | 678,029 | 100 | 1500 | 339,339... | 297,619 | 60 | 1285 | 25 |
| 3 | 671,2385 | 325 | 4255 | 233,064... | 510,605 | 225 | 1120 | 128,955... | 546,772 | 230 | 2425 | 16 |
| 4 | 683,263 | 80 | 1365 | 203,812... | 588,398 | 75 | 1535 | 190,093... | 501,727 | 0 | 1360 | 18 |
| 5 | 514,029 | 90 | 1060 | 188,892... | 326,2425 | 115 | 735 | 73,9516... | 467,4645 | 115 | 1045 | 13 |
| 6 | 699,0255 | 0 | 1475 | 300,340... | 581,174 | 0 | 1385 | 334,288... | 353,9635 | 0 | 965 | 17 |
| 7 | 769,152 | 195 | 3040 | 284,879... | 525,596 | 270 | 2685 | 179,008... | 536,388 | 195 | 4180 | 20 |
| 8 | 696,916 | 200 | 1370 | 239,031... | 645,429 | 120 | 2550 | 273,619... | 562,5045 | 55 | 3695 | 16 |

Rys. 8.5 Moduł przygotowania danych – standaryzacja atrybutu decyzyjnego.

ExIM

Import and transform teeth images Create teeth knowledge base Create decision table Remove inconsistencies Create rules System Expert

Knowledge base file:

Knowledge base

| No. | Tooth type | Bracket type | Adhesive system | Polishing type | Damage |
|-----|------------|--------------|------------------|----------------|--------|
| 1 | kły | metalowy | klasyczny | frez | MEDIUM |
| 2 | kły | metalowy | klasyczny | frez | MEDIUM |
| 3 | kły | metalowy | klasyczny | frez | HIGH |
| 4 | kły | metalowy | klasyczny | frez | MEDIUM |
| 5 | kły | metalowy | klasyczny | frez | MEDIUM |
| 6 | kły | metalowy | klasyczny | gumka | HIGH |
| 7 | kły | metalowy | klasyczny | gumka | HIGH |
| 8 | kły | metalowy | klasyczny | gumka | MEDIUM |
| 11 | kły | ceramiczny | klasyczny | gumka | MEDIUM |
| 12 | kły | metalowy | samowytrawiający | frez | MEDIUM |
| 13 | kły | metalowy | samowytrawiający | frez | MEDIUM |

☒ Quality method ☐ Quantity method

Rys. 8.6 Moduł usuwania niespójności w tablicy decyzyjnej.

W przypadku zastosowania metody ilościowej otrzymano 28 obiektów (Rys. 8.7), które posłużyły do utworzenia reguł decyzyjnych. Przy czym metoda ilościowa została uzupełniona funkcją wykrywania kombinacji atrybutów warunkowych, które nie wystąpiły w wejściowej tablicy decyzyjnej. W tym przypadku program wykrył 8 obiektów, których kombinacje atrybutów warunkowych nie były brane pod uwagę

w wejściowej tablicy decyzyjnej. Obiekty te mogą zostać wykorzystane do generowania reguł tylko w przypadku uzupełnienia wartości atrybutu decyzyjnego przez eksperta.

The screenshot shows the ExIM software interface. The 'Decision table' tab is active, displaying a table with 6 columns: No., Tooth type, Bracket type, Adhesive system, Polishing type, and Damage. The table contains 10 rows of data. Below the table, the 'System Expert data details' section shows the results of the optimization process.

| No. | Tooth type | Bracket type | Adhesive system | Polishing type | Damage |
|-----|------------|--------------|------------------|----------------|---------|
| 62 | kły | ceramiczny | klasyczny | gumka | MEDIUM |
| 90 | kły | kompozytowy | samowytrawiający | gumka | UNKNOWN |
| 25 | siekacze | metalowy | klasyczny | frez | MEDIUM |
| 154 | kły | ceramiczny | samowytrawiający | gumka | UNKNOWN |
| 115 | kły | metalowy | klasyczny | gumka | HIGH |
| 70 | siekacze | ceramiczny | samowytrawiający | gumka | UNKNOWN |
| 17 | siekacze | metalowy | samowytrawiający | gumka | UNKNOWN |
| 212 | siekacze | kompozytowy | klasyczny | gumka | UNKNOWN |
| 206 | kły | metalowy | samowytrawiający | gumka | UNKNOWN |
| 87 | kły | kompozytowy | samowytrawiający | frez | MEDIUM |

System Expert data details

☒ Minimal set of rules ☐ Complete set of rules Generate rules

DONE
 Number of samples after second optimization: 28
 Correct decision paths: 15
 Conflicted decision paths: 13
 Missing decision paths: 0
 Total decision paths: 28

Rys. 8.7 Wynik usuwania niespójności metodą ilościową.

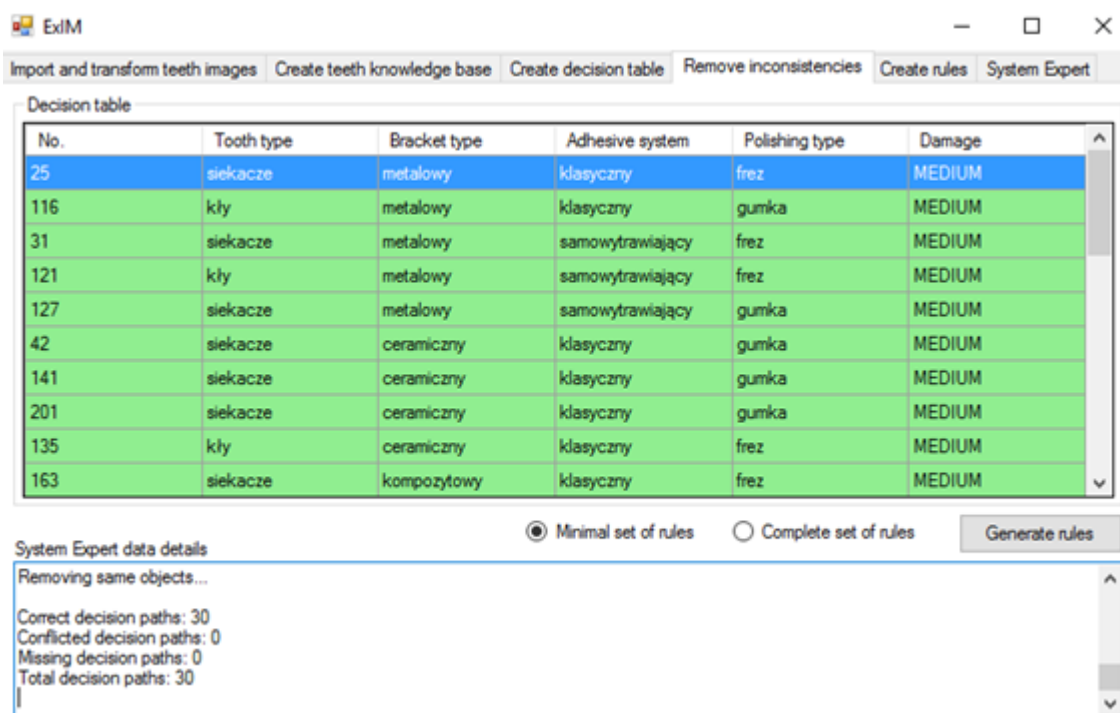
W przypadku decyzji o zmianie wartości atrybutu decyzyjnego przez eksperta – program umożliwia jego modyfikację po dwukrotnym kliknięciu komórki (Rys. 8.8).

The screenshot shows the ExIM software interface with the 'Decision table' tab active. The table is the same as in Rys. 8.7. The 'Damage' column for row 154 is highlighted, and a dropdown menu is open, showing the available options: UNKNOWN, HIGH, MEDIUM, and SMALL.

| No. | Tooth type | Bracket type | Adhesive system | Polishing type | Damage |
|-----|------------|--------------|------------------|----------------|---------|
| 62 | kły | ceramiczny | klasyczny | gumka | MEDIUM |
| 90 | kły | kompozytowy | samowytrawiający | gumka | UNKNOWN |
| 25 | siekacze | metalowy | klasyczny | frez | MEDIUM |
| 154 | kły | ceramiczny | samowytrawiający | gumka | UNKNOWN |
| 115 | kły | metalowy | klasyczny | gumka | UNKNOWN |
| 70 | siekacze | ceramiczny | samowytrawiający | gumka | HIGH |
| 17 | siekacze | metalowy | samowytrawiający | gumka | MEDIUM |
| 212 | siekacze | kompozytowy | klasyczny | gumka | SMALL |
| 206 | kły | metalowy | samowytrawiający | gumka | UNKNOWN |
| 87 | kły | kompozytowy | samowytrawiający | frez | UNKNOWN |


Rys. 8.8 Zmiana wartości atrybutu decyzyjnego np.: w przypadku wystąpienia równej liczby obiektów niespójnych, posiadających jednakową wartość atrybutu decyzyjnego.

Metoda jakościowa opisana w podrozdziale 5.5 ma za zadanie usunięcie obiektu, którego posiada mniejszą dokładność dolnego i górnego przybliżenia. Metoda wykryła 30 unikatowych obiektów (Rys. 8.9)



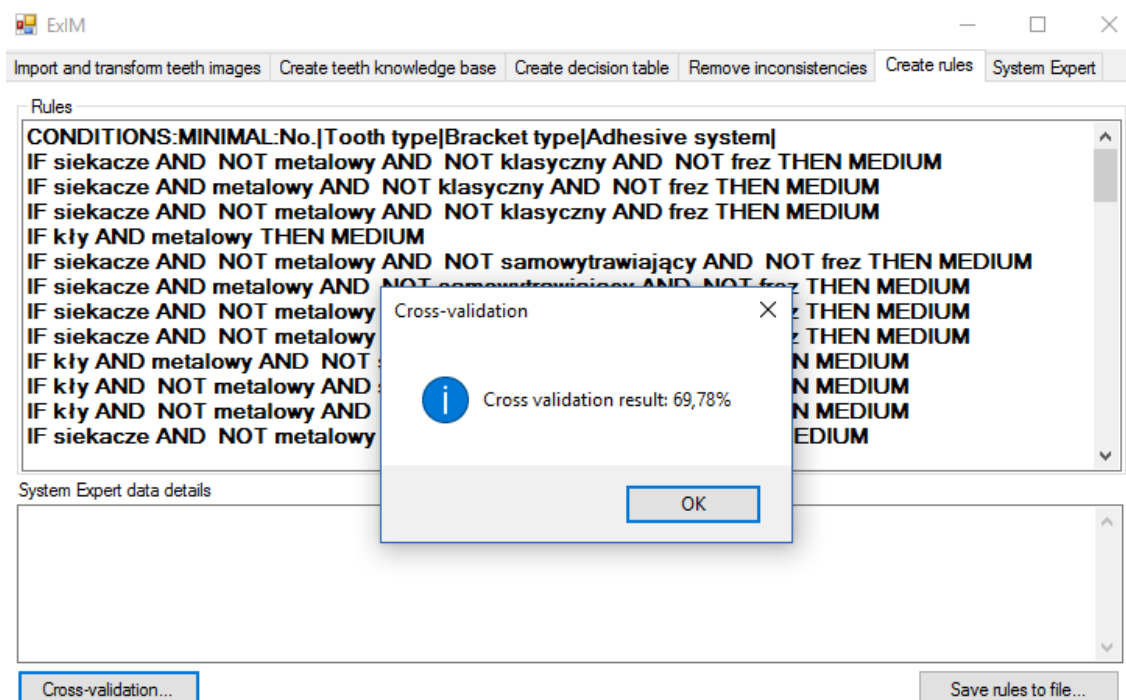
Rys. 8.9 Wynik usuwania niespójności metodą jakościową.

W module *Remove inconsistencies* wykorzystano metodę prostego generowania reguł dla każdego z obiektów tablicy, jak również alternatywnie algorytm generowania reguł minimalnych. Moduł ten uzupełniono możliwością weryfikacji otrzymanych reguł za pomocą walidacji krzyżowej. Wygenerowane reguły można eksportować do plików txt.



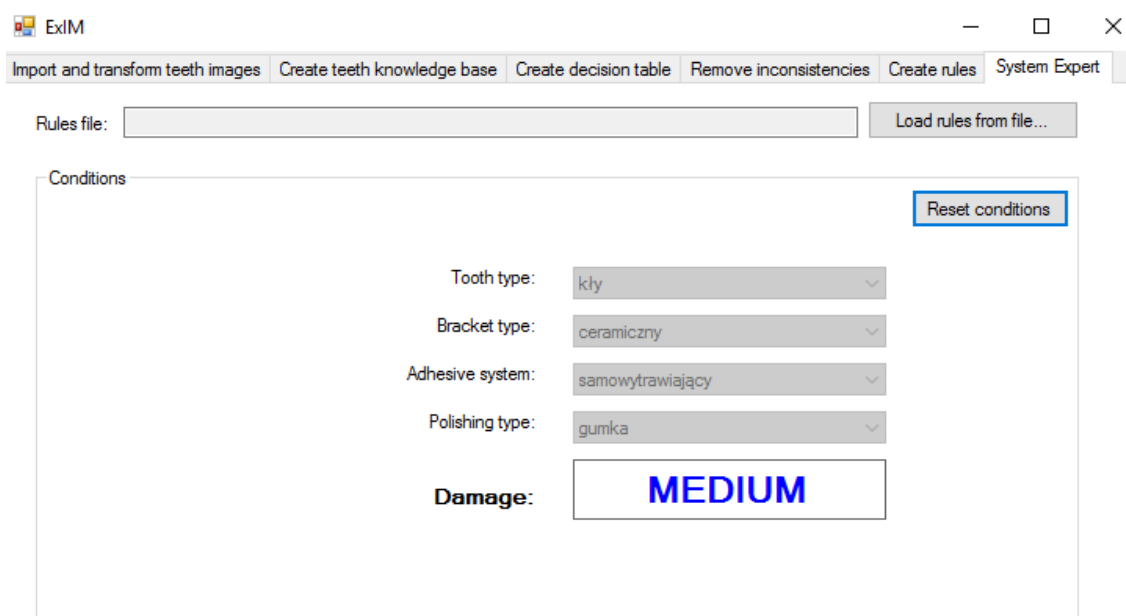
Rys. 8.10 Opcje generowania reguł.

W module *Create rules* można przeglądać wygenerowane reguły zweryfikować je za pomocą walidacji krzyżowej. Na Rys. 8.11 przedstawiono wygenerowane reguły decyzyjne oraz wynik walidacji krzyżowej - 69,78%.



Rys. 8.11 Wyniki analizy – utworzone reguły decyzyjne.

W module *System Expert* z wygenerowanych reguł powstaje klasyfikator korzystający z wnioskowania w przód. Przykład odpowiedzi systemu określający stopień uszkodzenia szkliwa w zależności od wybranych czynników przedstawiono na Rys. 8.12.



Rys. 8.12 Przykład odpowiedzi systemu.

8.1.3 Podsumowanie i ocena metody

Zastosowanie dwuetapowej metody do ekstrakcji cech z obrazów stomatologicznych oraz eksploracji danych pozwoliło zweryfikować możliwości oprogramowania na danych rzeczywistych. Ekspert z dziedziny stomatologii ocenił poprawność wyników, jako bardzo dobre. Dzięki zastosowaniu dwuetapowej metody szybko i precyzyjnie można określić wielkość ubytków szkliwa i zastosować odpowiednie leczenie. Obecnie oprogramowanie wzbogacone o funkcje niezbędne dla lekarza stomatologa jest testowane w jego pracy.

8.2 Obrazy mikroskopowe złącz zgrzewanych wykonywanych metodą Friction Stir Welding

Proponowana metoda oraz zrealizowane oprogramowanie zostały wykorzystane również do określenia wytrzymałości złącz wykonywanych metodą Friction Stir Welding. Obrazy stanowiące dane wejściowe dla metody pozyskano we współpracy z Instytutem Spawalnictwa w Gliwicach.

Metoda Friction Stir welding polega na łączeniu blach za pomocą narzędzia składającego się z wieńca oporowego oraz trzpienia, wykonującego ruch obrotowy i posuwisty. Materiał blach zostaje połączony za pomocą odkształcenia plastycznego. Więcej informacji o tej metodzie można znaleźć w publikacji [110]

Danymi wejściowymi jest seria 51 obrazów przekroju poprzecznego złącz FSW zarejestrowanych za pomocą mikroskopu optycznego. Makrostrukturę wykonano za pomocą oprogramowania Microsoft ICE [111]. Przykład badanego obrazu przedstawiono na Rys. 8.13.




Rys. 8.13 Przekrój poprzeczny złącza 6068 wykonanego w procesie FSW.

8.2.1 Etap pierwszy — analiza i przetwarzanie obrazów

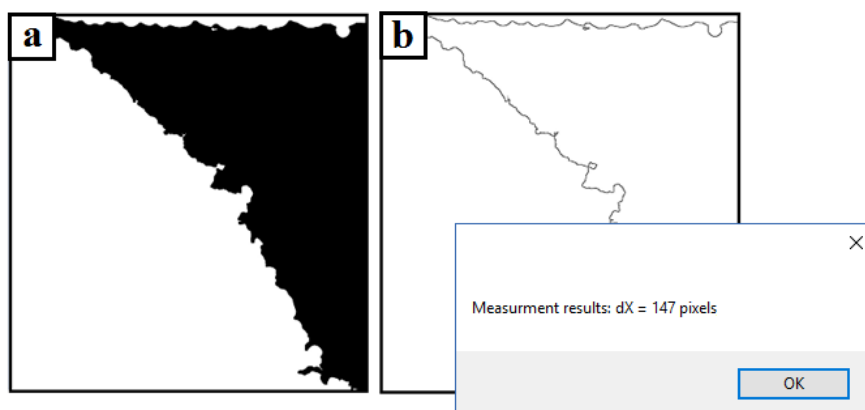
W module Import and transform images poddano obrazy operacjom w celu wykrycia krawędzi zgrzewu. Początkowo obraz RGB poddano filtracji medianowej w

celu usunięcia szumów a następnie przeprowadzono operację binaryzacji adaptacyjnej obrazu. Wynik binaryzacji przedstawiono na Rys. 8.14



Rys. 8.14 Binaryzacja obrazu.

Obraz poddany operacjom morfologicznym Rys. 8.15a pozwolił wyszukać krawędzie złącza Rys. 8.15a. Wyodrębnienie krawędzi pozwoliło na pomiar narzędziem *Measure* interesujących wielkości tj.: grubość blachy (*Thickness*), średnica wieńca oporowego (*Shoulder diameter*), średnica trzpienia (*Pin diameter*), długość trzpienia (*Pin length*).



Rys. 8.15 a) obraz poddany operacją morfologicznym, b) wynik wyznaczenia krawędzi zgrzeiny z pomiarem grubości blachy.

Następnie na podstawie informacji otrzymanych od eksperta dokonano wyznaczenia prawdopodobnej prędkości liniowej, z jaką zostało wykonane złącze.

Powyższe operację wykonano na pozostałych zdjęciach serii. Wyekstrahowane dane zapisano w pliku.CSV za pomocą *Transform image(s) and export to CSV(s)*.

8.2.2 Drugi etap metody – ekstrakcja wiedzy

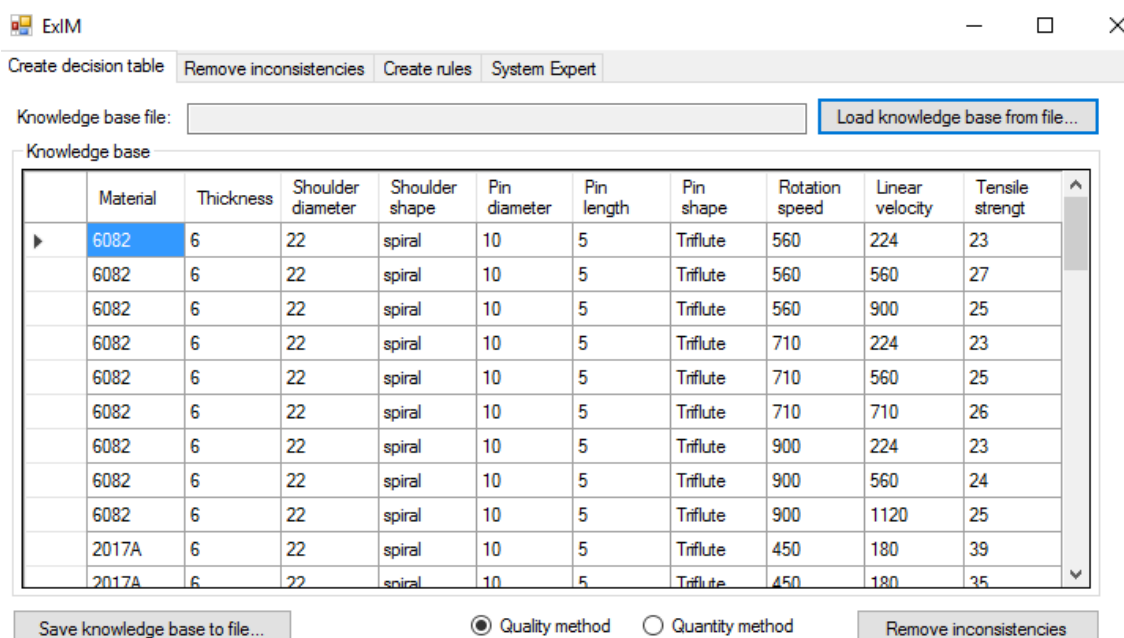
Następnie na podstawie wiedzy eksperta otrzymane dane zostały uzupełnione pozostałymi atrybutami warunkowymi:

- *Material*={6082, 2017A}
- *Shoulder shape*={spiral}
- *Pin shape*={Triflute, cone}

oraz atrybutem decyzyjnym:

- *Tensile strength*

Dane wyekstrahowane z obrazów cyfrowych oraz ww. atrybuty posłużyły do stworzenia tablicy decyzyjnej pokazanej na Rys. 8.16.



| | Material | Thickness | Shoulder diameter | Shoulder shape | Pin diameter | Pin length | Pin shape | Rotation speed | Linear velocity | Tensile strength |
|---|----------|-----------|-------------------|----------------|--------------|------------|-----------|----------------|-----------------|------------------|
| ▶ | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 560 | 224 | 23 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 560 | 560 | 27 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 560 | 900 | 25 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 710 | 224 | 23 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 710 | 560 | 25 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 710 | 710 | 26 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 900 | 224 | 23 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 900 | 560 | 24 |
| | 6082 | 6 | 22 | spiral | 10 | 5 | Triflute | 900 | 1120 | 25 |
| | 2017A | 6 | 22 | spiral | 10 | 5 | Triflute | 450 | 180 | 39 |
| | 2017A | 6 | 22 | spiral | 10 | 5 | Triflute | 450 | 180 | 35 |

Rys. 8.16 Wejściowa tablica decyzyjna.

Kolejnym krokiem metody jest analiza spójności tablicy decyzyjnej. Usunięcie niespójności wykonano metodą ilościową w rezultacie otrzymano 29 unikatowych obiektów oraz 10 obiektów, których wartość atrybutu decyzyjnego należy skonsultować z ekspertem dziedzinowy (Rys. 8.16).

ExIM

Create decision table Remove inconsistencies Create rules System Expert

Decision table

| Material | Thickness | Shoulder diameter | Shoulder shape | Pin diameter | Pin length | Pin shape | Rotation speed | Linear velocity | Tensile strengt |
|----------|-----------|-------------------|----------------|--------------|------------|-----------|----------------|-----------------|-----------------|
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 710 | 355 | 26 |
| AK9 | 6 | 22 | spiral | 10 | 5 | Triflute | 900 | 560 | UNKNOWN |
| AK9 | 6 | 22 | spiral | 10 | 5 | Triflute | 900 | 224 | UNKNOWN |
| AK9 | 6 | 22 | spiral | 10 | 5 | Triflute | 900 | 900 | UNKNOWN |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 710 | 180 | 15 |
| AK9 | 6 | 22 | spiral | 10 | 5 | Triflute | 710 | 560 | 17 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 560 | 18 |
| AK9 | 6 | 22 | spiral | 10 | 5 | Triflute | 560 | 1120 | 19 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 20 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 22 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 23 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 24 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 25 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 26 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 27 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 30 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 32 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 35 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 36 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 38 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 39 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 40 |
| 6082 | 3 | 16 | spiral | 5 | 5 | cone | 900 | 355 | 5 |

System Expert data details

☒ Minimal set of rules ☐ Complete set of rules

DONE

Number of samples after second optimization: 39

Correct decision paths: 29


Conflicted decision paths: 10

Missing decision paths: 0

Total decision paths: 39

Rys. 8.17 Wynik usunięcia niespójności metodą ilościową.

Następnie w module *Create rules* wygenerowano reguły dwoma metodami w celu porównania ich działania. Wynik walidacji reguł otrzymanych metodą ilościową przedstawiono na Rys. 8.18.



Rys. 8.18 Wynik walidacji reguł wygenerowanych metoda ilościową.

W module *System Expert* otrzymujemy prosty klasyfikator a prezentacja jego działania została pokazana na Rys. 8.19.

ExIM

Create decision table Remove inconsistencies Create rules System Expert

Rules file: Load rules from file...

Conditions

Reset conditions

Thickness: 3

Shoulder diameter: 16

Shoulder shape : spiral

Pin diameter : 5

Pin length: 5

Pin shape: cone

Rotation speed: 900

Linear velocity: 560

Tensile strengt: 24

Rys. 8.19 Klasyfikator pozwalający przewidzieć wytrzymałość złącza FSW na podstawie zadanych parametrów.

8.2.3 Podsumowanie i ocena metody

Zastosowanie dwuetapowej metody eksploracji danych z rzeczywistych zdjęć mikroskopowych złączy wykonanych metodą Friction Stir Welding dało obiecujące wyniki. Specjaliści z Instytutu Spawalnictwa w Gliwicach rekomendują metodę, jako możliwą do wdrożenia. Jednak jego zastosowanie ukierunkowane jest na archiwizację danych. Dzięki zastosowaniu programu użytkownik posiada szybki dostęp zarówno do obrazów poszczególnych złączy jak również do parametrów zgrzewania.

9 Podsumowanie

Podstawowym celem niniejszej pracy było opracowanie dwuetapowej metody wydobywania wiedzy z obrazów cyfrowych, integrującej analizę obrazów cyfrowych ukierunkowaną na ekstrakcję cech jakościowych i ilościowych, z metodami ekstrakcji wiedzy, wykorzystującymi eksploatacyjną analizę danych. W myśl tezy zawartej w podrozdziale 1.1, proponowana metoda pozwolić miała na prowadzenie nowego rodzaju badań eksploracyjnych, ukierunkowanych na wydobywanie wiedzy z obrazów cyfrowych, umożliwiających tworzenie regułowych baz wiedzy dla systemów wspomagania decyzji. Rzeczywiście zaproponowana metoda pozwala na prowadzenie takich badań, systematyzując proces ich realizacji oraz oferując wsparcie w postaci dedykowanego oprogramowania.

Zrealizowany w ramach pracy system informatyczny implementuje proponowaną metodę, stanowiąc jednocześnie środowisko jej eksperymentalnej weryfikacji. Choć proponowana metoda w sensie koncepcyjnym wydaje się prosta, jej implementacja oraz realizacja oprogramowania okazała się zagadnieniem złożonym. Istotnym problemem okazała się swoista interdyscyplinarność metody — łączy ona dwie z pozoru odrębne dziedziny informatyki: analizę obrazów i eksplorację danych. Na każdym z etapów autorka pracy spotykała się z wielością możliwych i potencjalnie użytecznych rozwiązań, stając przed trudnym wyborem wariantów najkorzystniejszych. Analiza obrazów oferuje szereg ciekawych metod i algorytmów, wybrano te, które wydawały się najkorzystniejsze z punktu widzenia odkrywania cech istotnych dla eksploracji danych, co przedstawiono w podrozdziale 3.4. Zastaw narzędzi stosowanych na pierwszym z etapów proponowanej metody może być łatwo rozszerzany o kolejne narzędzia, zrealizowany system jest na to przygotowany. Jest to zagadnienie istotne, bowiem specyfika obrazów dla pewnych konkretnych zastosowań może wymagać rozszerzenia zastawu oferowanych metod analizy obrazu.

Analiza dostępnych metod eksploracji danych, pozwoliła wytypować teorię zbiorów przybliżonych, jako najlepszym rozwiązaniem pod względem jej skuteczności dla danych będących wynikiem analizy obrazów. Szerszą motywację zawarto w podrozdziale 4.5. Warto tutaj zwrócić uwagę, że teoria zbiorów przybliżonych dostarcza spójnych podstaw teoretycznych oraz metodologicznych dla sygnalizowanych problemów związanych z odkrywaniem wiedzy w obrazach cyfrowych, formalnie opisując dane wejściowe w postaci systemu informacyjnego oraz

tablicy decyzyjnej, oferując skuteczne metody analizy tak reprezentowanych danych oraz algorytmy generowania reguł decyzyjnych. W aktualnej wersji proponowanej metody zaproponowano wykorzystanie reguł decyzyjnych, jako że głównym obszarem zastosowania metody są zadania klasyfikacyjne. W ramach pracy rozważono jednak również możliwość wykorzystania metod asocjacyjnych, które wydają się ciekawym narzędziem poszukiwania nowych prawidłowości oraz powiązań występujących w obrazach cyfrowych. Planuje się kontynuację badań nad wykorzystaniem reguł asocjacyjnych, jako narzędzia pogłębionej analizy danych. Również na etapie ekstrakcji wiedzy zarówno sama metoda, jak i implementujące ją oprogramowanie, otwarte są na alternatywne metody analizy danych tabelarycznych oraz nowe metody ekstrakcji reguł — zarówno decyzyjnych jak i asocjacyjnych.

Zrealizowane oprogramowanie stało się środowiskiem badań proponowanej metody. Badania realizowano na obrazach testowych pozyskiwanych z różnorodnych źródeł internetowych. Wstępne eksperymenty pozwoliły stwierdzić, że metoda jest obiecująca a oprogramowanie praktycznie użyteczne. Postanowiono przeprowadzić eksperymenty na danych rzeczywistych, będących obrazami cyfrowymi pozyskanymi w wyniku współpracy w ekspertami z Pomorskiego Uniwersytetu Medycznego w Szczecinie oraz Instytutu Spawalnictwa w Gliwicach. Te właśnie eksperymenty zostały przedstawione w rozdziale 8.

W przypadku badań dotyczących obrazów stomatologicznych dokonano rozszerzenia pierwotnego zestawu metod analizy obrazów, dostosowując pierwszy etap do specyfiki rozważanego problemu. Okazało się to realizowalne zarówno w aspekcie metodycznym jak i implementacyjnym, rozszerzając właściwości funkcjonalne oprogramowania. Proponowana metoda zyskała akceptację ekspertów stomatologicznych, jednoznacznie stwierdzających, że ich możliwości badawcze mogą być istotnie rozszerzone — uzyskanie reguł wspomagających klasyfikację rozważanych przypadków bezpośrednio z danych obrazowych nie było wcześniej dla nich możliwe. Podobnie było w przypadku złącz FSW, tutaj również eksperci pozytywnie ocenili potencjał metody oraz użyteczność oprogramowania.

Istotnym elementem proponowanej metody jest usystematyzowanie procesu odkrywania wiedzy w obrazach — metoda dzieli ten proces na wyraźne dwa etapy oraz ich składowe, posługując się odpowiednimi metodami reprezentacji danych oraz wyników w postaci reguł. W każdej z faz realizacji metody, możliwe jest zapisywanie wyników pośrednich, tak aby możliwe było wznowienie prac w dowolnym momencie

działania metody. Tak zdefiniowana metodyka badań pozwala na — sygnalizowaną już wcześniej — rozszerzalność oraz wariantowość stosowanych narzędzi. Ważnym elementem wydaje się również włączenie eksperta dziedzinowego w poszczególne fazy realizacji metody. Jego specjalizowana wiedza jest nieocenionym czynnikiem wpływającym na skuteczność i użyteczność proponowanej metody.

Przygotowanie różnych wariantów realizacji poszczególnych faz metody otwiera ciekawe możliwości badawcze. Dla zadanej serii obrazów można przykładowo analizować wpływ wyboru metody analizy obrazów lub jej parametrów na postać tablicy decyzyjnej oraz postać wygenerowanych reguł. Analogicznie, przy zadanych parametrach analizy obrazów można przykładowo przeprowadzać eksperymenty związane z wpływem metod usuwania niespójności czy dyskretyzacji atrybutów ciągłych na działanie klasyfikatora regułowego. Te ciekawe eksperymenty nie mogły zostać przeprowadzone ze względu na ograniczone ramy niniejszej pracy oraz ograniczenia czasowe, są jednak planowane jako następny etap badań. Istotnym elementem takich badań będzie udział ekspertów dziedzinowych, kompetentnych w zakresie oceny rozważanych wariantów. W niektórych z nich, ewaluacja może być realizowana obiektywnymi metodami informatycznymi (np. ocena jakości reguł w kontekście danych testowych), część ocen będzie miała jednak charakter subiektywny (np. ocena użyteczności reguł w kontekście rozważanej dziedziny problemu).

Podsumowując, można stwierdzić, że proponowana w pracy metoda ekstrakcji wiedzy z obrazów cyfrowych uzupełnia istniejącą lukę pomiędzy metodami analizy obrazów oraz eksploracji danych, stanowiąc interesujące narzędzie badawcze. Zrealizowany system, implementujący rozważaną metodę, jest oprogramowaniem o charakterze unikatowym, oferując możliwość wygodnej pracy również dla użytkowników nieposiadających głębszej wiedzy informatycznej. Wstępne opinie użytkowników systemu potwierdzają jego użyteczność, rozszerzającą możliwość realizacji badań w przedmiotowych dziedzinach.

10 Spis rysunków

| | |
|---|----|
| Rys. 2.1. Ilustracja koncepcji proponowanej metody ekstrakcji wiedzy z obrazów cyfrowych. | 15 |
| Rys. 3.1. Podział metod analizy i przetwarzania obrazu. | 17 |
| Rys. 3.2. Obraz powierzchni zęba zarejestrowany za pomocą tomografu optycznego. | 19 |
| Rys. 3.3. a) Obraz źródłowy zęba uzyskany za pomocą tomografu optycznego b) obraz po zastosowaniu operacji normalizacji. | 21 |
| Rys. 3.4. a) Obraz źródłowy zęba uzyskany za pomocą tomografu optycznego b) Obraz po operacji wyrównania histogramu. | 22 |
| Rys. 3.5. a) obraz źródłowy uzyskany za pomocą tomografu optycznego b) histogram rozkładu stopni szarości. | 23 |
| Rys. 3.6. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) obraz po zastosowaniu operacji binaryzacji z dolnym progiem. | 24 |
| Rys. 3.7. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) obraz po zastosowaniu operacji binaryzacji z górnym progiem. | 25 |
| Rys. 3.8. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) obraz po zastosowaniu operacji binaryzacji z podwójnym ograniczeniem. | 26 |
| Rys. 3.9. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu binaryzacji warunkowej. | 27 |
| Rys. 3.10. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu konwulsji. | 28 |
| Rys. 3.11. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru dolnoprzepustowego – średnia. | 29 |
| Rys. 3.12. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru dolnoprzepustowego Gamma. | 30 |
| Rys. 3.13. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru górnoprzepustowego Roberts'a. | 30 |
| Rys. 3.14. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru górnoprzepustowego – mean removal. | 31 |
| Rys. 3.15. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu Laplasjanu. | 32 |
| Rys. 3.16. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru medianowego. | 33 |
| Rys. 3.17. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu filtru adaptacyjnego. | 34 |
| Rys. 3.18. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji logicznych – suma obrazów oraz suma obrazu z filtrem medianowym. | 35 |
| Rys. 3.19. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) F-obraz fazy po wykonaniu transformaty Fouriera. | 36 |
| Rys. 3.20. F-obraz amplitudy po zastosowaniu transformaty Fouriera. | 36 |
| Rys. 3.21. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji erozji. | 38 |
| Rys. 3.22. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji dyatacji. | 38 |

| | |
|---|-----|
| Rys. 3.23. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji otwarcia..... | 39 |
| Rys. 3.24. a) Obraz źródłowy uzyskany za pomocą tomografu optycznego b) Obraz po zastosowaniu operacji otwarcia..... | 40 |
| Rys. 3.25. Pomiar pola powierzchni zajmowanego przez komórki nowotworowe jelita grubego.[26]..... | 41 |
| Rys. 3.26. Najczęściej stosowane metody przetwarzania obrazów medycznych i stomatologicznych. | 44 |
| Rys. 3.27. Wyselekcjonowane metody analizy i przetwarzania obrazu. | 46 |
| Rys. 3.28. Schemat pierwszego etapu metody ukierunkowanej na ekstrakcję cech. | 47 |
| Rys. 4.1. Schemat drugiego etapu metody. | 48 |
| Rys. 6.1 Schemat sekwencyjnego pokrywania[89]..... | 77 |
| Rys. 7.1 Obraz dermatoskopowy nowotworu skóry. | 80 |
| Rys. 7.2 Pierwszy etap pracy z systemem..... | 80 |
| Rys. 7.3 Okno startowe aplikacji z możliwością wyboru danych wejściowych. | 81 |
| Rys. 7.4 Moduł Import and transform images. | 81 |
| Rys. 7.5 Wybór lokalizacji wczytywanych obrazów. | 82 |
| Rys. 7.6 Ładowanie obrazów — zarządzanie zdjęciami. | 82 |
| Rys. 7.7 Operacja zamknięcia z opcją modyfikacji parametrów. | 83 |
| Rys. 7.8 Operacja Progowania z opcją modyfikacji parametrów. | 84 |
| Rys. 7.9 Ustawienie parametrów erozji. | 84 |
| Rys. 7.10 Sterowanie kolejnością wykonywanych operacji analizy i przetwarzania obrazu..... | 85 |
| Rys. 7.11 Przetwarzanie obrazu czerniaka w celu uzyskania informacji o średnicy znamienia, jakości brzegów oraz koloru znamienia. | 85 |
| Rys. 7.12 Drugi etap pracy z programem. | 87 |
| Rys. 7.13 Wejściowa tablica decyzyjna. | 87 |
| Rys. 7.14 Kolejny etap metody – usuwanie niespójności. | 87 |
| Rys. 7.15 Wybór metody usuwania niespójności. | 88 |
| Rys. 7.16 Wynik usuwania niespójności metodą ilościową..... | 88 |
| Rys. 7.17 Czarty etap pracy z programem. | 89 |
| Rys. 7.18 Moduł Create rules..... | 89 |
| Rys. 7.19 Ostatni etap pracy z programem. | 90 |
| Rys. 7.20 Wczytywanie reguł | 90 |
| Rys. 7.21 Moduł System Expert z przykładem odpowiedzi systemu. | 90 |
| Rys. 8.1 Proces pozyskania zdjęć. | 93 |
| Rys. 8.2 Przetwarzanie zdjęć w module Import and transform images. | 93 |
| Rys. 8.3 a)obraz źródłowy b) wyekstrahowany kontur zęba. | 94 |
| Rys. 8.4 a) obraz źródłowy b) wyznaczenie centralnej powierzchni zęba. | 95 |
| Rys. 8.5 Moduł przygotowania danych – standaryzacja atrybutu decyzyjnego..... | 97 |
| Rys. 8.6 Moduł usuwania niespójności w tablicy decyzyjnej..... | 97 |
| Rys. 8.7 Wynik usuwania niespójności metodą ilościową..... | 98 |
| Rys. 8.8 Zmiana wartości atrybutu decyzyjnego np.: w przypadku wystąpienia równej liczby obiektów niespójnych, posiadających jednakową wartość atrybutu decyzyjnego. | 98 |
| Rys. 8.9 Wynik usuwania niespójności metodą jakościową..... | 99 |
| Rys. 8.10 Opcje generowania reguł. | 99 |
| Rys. 8.11 Wyniki analizy – utworzone reguły decyzyjne..... | 100 |
| Rys. 8.12 Przykład odpowiedzi systemu..... | 100 |
| Rys. 8.13 Przekrój poprzeczny złącza 6068 wykonanego w procesie FSW..... | 101 |

| | |
|--|-----|
| Rys. 8.14 Binarizacja obrazu..... | 102 |
| Rys. 8.15 a) obraz poddany operacją morfologicznym, b) wynik wyznaczania krawędzi zgrzeiny z pomiarem grubości blachy..... | 102 |
| Rys. 8.16 Wejściowa tablica decyzyjna..... | 103 |
| Rys. 8.17 Wynik usunięcia niespójności metodą ilościową..... | 104 |
| Rys. 8.18 Wynik walidacji reguł wygenerowanych metoda ilościową..... | 104 |
| Rys. 8.19 Klasyfikator pozwalający przewidzieć wytrzymałość złącza FSW na podstawie zadanych parametrów..... | 105 |

11 Spis tabel

| | |
|---|----|
| <i>Tabela 1 Tablica decyzyjna</i> | 67 |
| <i>Tabela 2 Przykładowa tablica decyzyjna</i> | 68 |

12 Literatura

- [1] A. Wójcicka, R. Simiński, and Z. Wróbel, “Analiza metod predykcji parametrów zgrzewania metodą Friction Stir Welding,” vol. 35, no. 2, 2014.
- [2] A. Wójcicka, R. Simiński, and Z. Wróbel, “The two-stage method that integrates image analysis,” *Stud. Inform.*, vol. 36, no. 1 (119), pp. 145–154, 2015.
- [3] B. Chanda and D. D. Majumder, *Digital Image Processing and Analysis*, Second. PHI Learning Pvt. Ltd., 2011.
- [4] R. Klette, T. Huang, and G. Gimel’farb, Eds., “Multi-Image Analysis,” in *Lecture Notes in Computer Science -10th International Workshop on Theoretical Foundations of Computer Vision Dagstuhl Castle, 201AD*, p. 296.
- [5] L. Moller-Jensen, “Classification of urban land cover based on expert systems, object models and texture,” *Comput. Environ. Urban Syst.*, vol. 21, pp. 291–302, 1997.
- [6] R. Tadeusiewicz, *Informatyka Medyczna*. Lublin: UMCS, 2011.
- [7] S. K. Wasan, V. Bhatnagar, and H. Kaur, “The impact of data mining techniques on medical diagnostics,” *Data Sci. J.*, vol. 5, pp. 119–126, 2006.
- [8] L. Shu-Hsien, C. Pei-Hui, and H. Pei-Yuan, “Data mining techniques and applications – A decade review from 2000 to 2011,” *Expert Syst. Appl.*, vol. 39, pp. 11303–11311, 2012.
- [9] Z. Pawlak, *Information System - theoretical foundation*. Warszawa: WNT, 1983.
- [10] Z. Pawlak and A. Skowron, “A rough set approach for decision rules generation,” in *ICS Research Report 23/93*, p. 1993.
- [11] M. Kurzyński, *Rozpoznawanie obrazów - metody statystyczne*. Wrocław: Wydawnictwo Politechniki Wrocławskiej, 1997.
- [12] W. Malina, S. Ablameyko, and W. Pawlak, *Podstawy cyfrowego przetwarzania obrazów*. Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2002.
- [13] N. Naniewski, *Morfologia matematyczna w przetwarzaniu obrazów*. Warszawa: Oficyna Wydawnicza PLJ, 1998.
- [14] R. Tadeusiewicz and P. Korohoda, *Komputerowa analiza i przetwarzanie obrazów*. 1997.
- [15] C. Watkins, A. Sadum, and S. Marenka, *Nowoczesne metody przetwarzania obrazu*. Warszawa: WNT, 1995.
- [16] L. Wojnar, K. J. Kurzydłowski, and J. Szala, *Praktyka analizy obrazu*. 2002.

- [17] L. Wojnar and M. Majorek, *Komputerowa analiza obrazu*. Kraków: Fotobit – Design, 1994.
- [18] Z. Wróbel and R. Koprowski, “Praktyka przetwarzania obrazów w programie Matlab.” Akademicka Oficyna Wydawnicza EXIT, Warszawa, p. 136, 2004.
- [19] J. Woźnicki, *Podstawowe techniki przetwarzania obrazów*. Warszawa: WKiŁ, 1996.
- [20] J. Zabrocki, *Grafika komputerowa – metody i narzędzia*. Warszawa: WNT, 1994.
- [21] K. Zieliński and M. Strzelecki, *Komputerowa analiza obrazu biomedycznego – wstęp do morfometrii i patologii ilościowej*. Warszawa-Łódź: PWN, 2002.
- [22] A. K. Johnson, L. R., Jain, “An efficient two-dimensional FFT algorithm,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 3, pp. 698–701, 1981.
- [23] J. C. Russ, *Image Processing Handbook*, Fifth Edit. New York: CRC Press, 2007.
- [24] J. Serra, *Image Analysis and Mathematical Morphology*. London: Academic Press, 1982.
- [25] S. G., “Zastosowanie metod morfologii matematycznej do detekcji i dekompozycji obrazów,” *Telekomun. i Tech. Inf.*, vol. 1–2, pp. 67–90, 2003.
- [26] A. Wójcicka, P. Jędrusik, M. Stolarz, R. Kubina, and Z. Wróbel, “Using analysis algorithms and image processing for quantitative description of colon cancer cells,” *Inf. Technol. Biomed.*, vol. 283, no. 3, pp. 385–395, 2014.
- [27] I. Bankman, *Handbook of Medical Image Processing and Analysis*, Second Edition, Second. Academic Press, 2008.
- [28] T. D. Klaus, *Guide to Medical Image Analysis. Method and Algorithms.*, Springer L. New York, 2012.
- [29] R. C. Gonzales and R. E. Woods, *Digital image processing*, Third. New Jersey: Prentice-Hall Inc, 2008.
- [30] D. J. Brennan et al., “Tumour-specific HMG-CoAR is an independent predictor of recurrence free survival in epithelial ovarian cancer,” *BMC Cancer*, vol. online, 2010.
- [31] R. Koprowski, M. Machoy, K. Woźniak, and Z. Wróbel, “Automatic method of analysis of OCT images in the assessment of the tooth enamel surface after orthodontic treatment with fixed braces,” *Biomed. Eng. Online*, vol. 13, no. 48, pp. 2–18, 2014.

- [32] P. Perona and J. Malik, "Scale-space and edge detection using anisotropic diffusion," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 12, no. 7, pp. 629–639, 1990.
- [33] Y. Hu and T. J. Dennis, "MAP estimation in image restoration by a local search enhanced genetic algorithm," in *6th int conf digital processing of signals in communications*, 1991, pp. 123–128.
- [34] H. D. Li, M. Kallergi, L. P. Clarke, V. K. Jain, and R. A. Clark, "Markov random field for tumor detection in digital mammography.," *IEEE Trans. Med. Imaging*, vol. 14, no. 3, pp. 565–576, 1995.
- [35] A. H. Baydush and C. E. Floyd, "Improved image quality in digital mammography with image processing," *Med. Phys.*, vol. 27, no. 7, pp. 1503–1508, 2000.
- [36] R. Highnam, J. Brady, N. Karssemeijer, and M. Yaffe, "A method and system for analysing tissue from images," *WO 2011015818 A1*, 2011.
- [37] J. L. Marroquin, B. C. Vemuri, S. Botello, E. Calderon, and A. Fernandez-Bouzas, "An accurate and efficient Bayesian method for automatic segmentation of brain MRI," *IEEE Trans. Med. Imaging*, vol. 21, no. 8, pp. 934–945, 2002.
- [38] C. A. Bouman and M. Shapiro, "A multiscale random field model for Bayesian image segmentation," *Trans. Image Process.*, vol. 3, no. 2, pp. 162–177, 1994.
- [39] D.-Z. Tian and Ming-Hu Ha, "APPLICATIONS OF WAVELET TRANSFORM IN MEDICAL IMAGE PROCESSING," in *IEEE*, 2004, pp. 1816–1821.
- [40] J. Wang and Y. Kang, "Study on Medical Image Processing Algorithm based on Contourlet Transform and Correlation Theory," in *IEEE*, 2008, pp. 233–238.
- [41] L. Tsair-Fwu, L. Chang-Yu, C. Pei-Ju, L. Chieh, W. Chang-Yu, and F. Chun-Hsiung, "Quantitative Coronary Analysis Medical Image Processing Improved by Combining Wavelet Edge Detection and Segmentation," in *IEEE*, 2009, pp. 1196–1199.
- [42] J. S. Suri, S. K. Setarehdan, and S. Singh, *Advanced Algorithmic Approaches to Medical Image Segmentation. State-of-the-Art. Applications in cardiology, neurology, mammography and pathology*. London: Springer-Verlag, 2002.
- [43] D. Pham, C. Xu, and J. Prince, "Current methods in medical image segmentation," *Annu. Rev. Biomed. Eng.*, vol. 2, pp. 315–337, 2000.
- [44] V. Mayer-Schönberger and K. Cukier, *Big data: A Revolution that Will Transform how We Live, Work, and Think*. Houghton Mifflin Harcourt, 2013.
- [45] T. Morzy, *Eksploracja danych*. Warszawa: Wydawnictwo Naukowe PWN, 2015.

- [46] U. Fayyad and G. Piatetsky-Shapiro, *Advances in Knowledge Discovery and Data Mining*. MIT Press, 1996.
- [47] M. S. Chen, J. Han, and P. S. Yu, "Data mining: an overview from a database perspective," *IEEE Trans. Knowl. Data Eng.*, vol. 8, pp. 866–883, 1996.
- [48] D. Hand, H. Mannila, and P. Smyth, *Eksploracja danych*. WNT, 2005.
- [49] P. N. Tan, M. Steinbach, and V. Kumar, *Introduction to Data mining*. Pearson Education, 2006.
- [50] J. Han and M. Kamber, *Data Mining: Concepts and Techniques*, 3 edition. Morgan Kaufmann, 2011.
- [51] I. H. Witten and E. Frank, *Data mining: practical machine learning tools and techniques with Java implementations*. Morgan Kaufmann Pub., 2000.
- [52] J. Stefanowski, "Algorytmy indukcji regół decyzyjnych w odkrywaniu wiedzy," *Politechnika Poznańska*, 2001.
- [53] T. Morzy, *Odkrywanie asocjacji: algorytmy i struktury danych*. OWN, 2004.
- [54] M. James, *Classification algorithms*. New York: Wiley, 1985.
- [55] J. R. Quinlan, "Induction of decision trees," *Mach. Learn.*, vol. 1, no. 1, pp. 81–106, 1986.
- [56] R. Agrawal and R. Srikant, "Fast Algorithms for Mining Association Rules," in *VLDB '94 Proceedings of the 20th International Conference on Very Large Data Bases*, 1994, pp. 487–499.
- [57] J. Han, J. Pei, and B. Mortazavi-Asl, "FreeSpan: frequent pattern-projected sequential pattern mining," in *Proc. 6th International Conference on Knowledge Discovery and Data Mining (KDD'00)*, 2000, pp. 355–359.
- [58] J. Han, J. Pei, and Y. Yin, "Mining frequent patterns without candidate generation," in *Proc. 2000 ACM-SIGMOD International Conference on Management of Data*, 2000, pp. 1–12.
- [59] J. Pei et al., "PrefixSpan: mining sequential patterns efficiently by prefix-projected pattern growth," in *Proc. 17th International Conference on Data Engineering (ICDE'01)*, 2001, pp. 215–224.
- [60] R. Srikant and R. Agrawal, "Mining generalized association rules," in *Proc. 21th International Conference on Very Large Data Bases (VLDB'95)*, 1995, pp. 407–419.

- [61] R. Srikant and R. Agrawal, "Mining quantitative association rules in large relational tables," in Proc. 1996 ACM-SIGMOD International Conference on Management of Data, 1996, pp. 1–12.
- [62] A. K. Jain and R. C. Dubes, Algorithms for Clustering Data. Englewood Cliffs, New Jersey: Prentice Hall, 1988.
- [63] A. K. Jain, M. N. Murty, and P. J. Flynn, "Data clustering: a survey," in ACM Computing Surveys, 1999, pp. 264–323.
- [64] L. Kaufman and P. J. Rousseeuw, Finding groups in data: an introduction to cluster analysis. John Wiley & Sons, 1990.
- [65] A. K. Jain and R. Dubes, Algorithms for Clustering Data. New Jersey: Prentice Hal, 1988.
- [66] S. Chakrabarti, Mining the Web: Discovering Knowledge from Hypertext Data. Morgan Kaufmann Pub., 2003.
- [67] B. Liu, Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data. Springer, 2007.
- [68] C. J. V. Rijsbergen, "Information Retrieval." 1979.
- [69] B. G. . Buchanan and E. Shortliffe, "Rule-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming," Massachusetts, 1984.
- [70] R. Davis, B. . Buchanan, and E. H. Shorliffe, "Production rules as a representation for a knowledge-based consultation program," Artif. Intel., vol. 8, pp. 15–45, 1977.
- [71] A. Kisielewicz, Sztuczna inteligencja i logika. WNT, 2014.
- [72] A. Wakulicz-Deja, A. Nowak-Brzezińska, and R. Simiński, Systemy Ekspertowe. Sosnowiec, 2009.
- [73] Z. Pawlak, "Rough Sets," Int. J. Inf. Comput. Sci., vol. 11, pp. 344–356, 1982.
- [74] A. Skowron, Z. Pawlak, J. Komorowski, and L. Polkowski, A rough set perspective on data and knowledge. Handbook of KDD. Oxford University Press, 2002.
- [75] R. Vashist and M. . Garg, "Rule Generation based on Reduct and Core: A Rough Set Approach," Int. J. Comput. Appl. (0975 – 8887), vol. 29, no. 9, pp. 1–5, 2011.
- [76] J. W. Grzymała-Busse, "LERS - a system for learning from examples based on rough sets," in Intelligent Decision Support. Handbook of Applications and Advances of the Rough Sets Theory, R. Słowinski, Ed. Norwell (MA): Kluwer Academic Publishers, 1992, pp. 3–18.
- [77] A. Wakulicz-Deja and P. Paszek, "Diagnose Progressive Encephalopathy Applying the Rough Set Theory," Int. J. Med. Inform., vol. 46, pp. 119–127, 1997.

- [78] A. Wakulicz-Deja, M. Boryczka, and P. Paszek, "Discretization of continuous attributes on Decision System in Mitochondrial Encephalomyopathies," in *Lecture Notes in Computer Science* 1424, 1998, pp. 483–490.
- [79] J. W. Grzymała-Busse, "LERS - a knowledge discovery system," in *Rough Sets in Knowledge Discovery 2. Applications, Case Studies and Software Systems*, Heidelberg: Physica-Verlag, 1999, p. 562–565.
- [80] W. University, RSES 2.1 Rough Set Exploration System. Warsaw, 2004.
- [81] A. Ohrn and J. Komorowski, "ROSETTA: A rough set toolkit for analysis of data. Proceedings of the Third International Joint Conference on Information Sciences," *Fifth Int. Work. Rough Sets Soft Comput.*, vol. 3, pp. 403–407, 1997.
- [82] I. Düntsch and G. Gediga, "The rough set engine GROBIAN," in *Proceedings of the 15th IMACS World Congress*, 1997.
- [83] S. Kotsiantis and D. Kanellopoulos, "Discretization Techniques: A recent survey," *GESTS Int. Trans. Comput. Sci. Eng.*, vol. 32, no. 1, pp. 47–58, 2006.
- [84] A. Skowron, J. Komorowski, Z. Pawlak, and L. Polkowski, *Rough sets: A tutorial. Rough fuzzy hybridization: A new trend in decision-making*. 1999.
- [85] J. Bazan, H. Nguyen, and M. Szczuka, "A view on Rough Set Concept Approximations," *Fundam. Informaticae*, vol. 59, pp. 107–118, 2004.
- [86] A. Skowron, H. Wang, A. Wojna, and J. Bazan, "Multimodal classification: case studies," *Trans. Rough Sets V*, pp. 224–239, 2006.
- [87] N. Tintarev and J. Masthoff, *Recommender Systems Handbook*, vol. 54. Springer, 2011.
- [88] Giarratano, J.C. and G. D. Riley, *Expert Systems: Principles and Programming*, Fourth Edi. Course Technology, 2004.
- [89] P. Cichosz, *Systemy uczące się*. Warszawa, 2000.
- [90] J. Bazan, "Metody wnioskowań aproksymacyjnych dla syntezy algorytmów decyzyjnych," *Uniwersytet Warszawski*, 1998.
- [91] J. Stefanowski, "On rough set based approaches to induction of decision rules," *Rough Sets Knowl. Discov.* 1.1, pp. 500–529, 1998.
- [92] J. Bazan, "A comparison of dynamic and non-dynamic rough set methods for extracting laws from decision tables," *Rough Sets Knowl. Discov.* 1, pp. 321–365, 1998.
- [93] Z. Pawlak and A. Skowron, "Rough sets and Boolean reasoning," *Inf. Sci. (Ny)*, vol. 177, no. 1, pp. 41–73, 2007.

- [94] J. Bazan, A. Skowron, and P. Synak, "Dynamic reducts as a tool for extracting laws from decisions tables," *Methodol. Intell. Syst.*, pp. 346–355, 1994.
- [95] J. W. Grzymała-Busse, "A new version of the rule induction system LERS," *Fundam. Informaticae*, vol. 31, no. 1, pp. 27–39, 1997.
- [96] J. W. Grzymała-Busse, "Rule Induction from Rough Approximations," *Springer Handb. Comput. Intell.*, pp. 371–385, 2015.
- [97] J. Bazan and M. Szczuka, "The rough set exploration system," *Trans. Rough Sets III.*, pp. 37–56, 2005.
- [98] R. Słowiński and J. Stefanowski, "Roughdas and Roughclass Software Implementations of the Rough Sets Approach," *Intell. Decis. Support*, pp. 445–456, 1992.
- [99] R. Słowiński and J. Stefanowski, "Rough family: software implementation of the rough set theory," *Rough Set Knowl. Discov.*, pp. 581–586, 1998.
- [100] R. S. Michalski, "On the quasi-minimal solution of the general covering problem," in *Proc. of 5th Int. Symp. on Information Processing FCIP'69*, 1969, pp. 125–128.
- [101] R. S. Michalski, I. Mozetic, J. Hong, and N. Lavrac, "The multi-purpose incremental learning system AQ15 and its testing application to three medical domains," in *Proc. of the 5th Nat. Conf. on AI*, 1986, p. 1041–1045.
- [102] R. S. Michalski and G. Tecuci, *Machine learning: a multistrategy approach*. Morgan Kaufmann, 1994.
- [103] P. Clark and R. Boswell, "Rule induction with CN2: some recent improvements," in *Proceedings of 5th European Working Session on Learning – ESWL 91 Porto*, 1991, pp. 151–163.
- [104] P. Clark and T. Niblett, "The CN2 induction algorithm," *Mach. Learn.*, vol. 3, pp. 261–283, 1989.
- [105] S. Dzeroski, B. Cestnik, and P. I., "Using the m-estimate in rule induction," *J. Comput. Inf. Technol.*, vol. 1, pp. 37–46.
- [106] J. Cendrowska, "PRISM, an algorithm for inducing modular rule," *Int. J. ManMachine Stud.*, vol. 27, pp. 349–370, 1987.
- [107] R. Srikant and R. Agrawal, "Mining sequential patterns: Generalizations and performance improvements," in *Data Mining*, Springer, 1996, pp. 1–17.

- [108] T. Scheffer, “Finding Association Rules That Trade Support Optimally against Confidence,” in 5th European Conference on Principles of Data Mining and Knowledge Discovery, 2001, pp. 424–435.
- [109] J. Sauvola and M. Pietikäinen, “Adaptive Document Image Binarization,” *Pattern Recognit.*, vol. 33, no. 2, pp. 225–236, 2000.
- [110] K. Mroczka, A. Wójcicka, and A. Pietras, “Characteristics of dissimilar FSW welds of aluminum alloys 2017A and 7075 on the basis of multiple layer research,” *J. Mater. Eng. Perform.*, vol. 22, pp. 2698–2705, 2013.
- [111] A. Wójcicka and Z. Wróbel, “The panoramic visualization of metallic materials in macro- and microstructure of surface analysis using Microsoft Image Composite Editor (ICE),” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7339, pp. 358–368, 2012.